



UNIVERSIDAD TÉCNICA DE AMBATO

FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E INDUSTRIAL

CARRERA DE INGENIERÍA EN ELECTRÓNICA Y COMUNICACIONES

TEMA:

“SEGMENTACIÓN Y ANÁLISIS DE IMÁGENES TERMOGRÁFICAS MEDIANTE
DESCRIPTORES DE TEXTURA SIMPLES”

Proyecto de Trabajo de Graduación Modalidad: TEMI Trabajo Estructurado de Manera Independiente, presentado previo la obtención del título de Ingeniera en Electrónica y Comunicaciones

SUBLINEA DE INVESTIGACIÓN: Procesamiento digital de señales e imágenes.

AUTOR: Tatiana Marianela Mejía Bayas

PROFESOR REVISOR: Ing. María Gabriela Pérez, PhD.

Ambato – Ecuador

Abril-2015

APROBACIÓN DEL TUTOR

En mi calidad de tutor del trabajo de investigación sobre el tema: “ **SEGMENTACIÓN Y ANÁLISIS DE IMÁGENES TERMOGRÁFICAS MEDIANTE DESCRIPTORES DE TEXTURA SIMPLES** ”, de la señorita Tatiana Marianela Mejía Bayas, estudiante de la Carrera de Ingeniería Electrónica y Comunicaciones, de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, de la Universidad Técnica de Ambato, considero que el informe de investigación reúne los requisitos suficientes para que continúe con los trámites y consiguiente aprobación de conformidad con el Art. 16 del Capítulo IV, del Reglamento de Graduación para Obtener el Título Terminal de Tercer Nivel de la Universidad Técnica de Ambato.

Ambato Abril, 2015

EL TUTOR

Ing. María Gabriela Pérez, PhD

AUTORÍA DE LA TESIS

El presente trabajo de investigación titulado: **“SEGMENTACIÓN Y ANÁLISIS DE IMÁGENES TERMOGRÁFICAS MEDIANTE DESCRIPTORES DE TEXTURA SIMPLES”**. Es absolutamente original, auténtico y personal, en tal virtud, el contenido, efectos legales y académicos que se desprenden del mismo son de exclusiva responsabilidad del autor.

Ambato Abril, 2015

Tatiana Marianela Mejía Bayas
CC: 1804465035

APROBACIÓN DEL TRIBUNAL DE GRADO

La Comisión Calificadora del presente trabajo conformada por los señores docentes aprobó el Informe Final del trabajo de graduación titulado **“SEGMENTACIÓN Y ANÁLISIS DE IMÁGENES TERMOGRÁFICAS MEDIANTE DESCRIPTORES DE TEXTURA SIMPLES”**, presentado por la señorita Tatiana Marianela Mejía Bayas de acuerdo al Art. 18 del Reglamento de Graduación para obtener el título Terminal de tercer nivel de la Universidad Técnica de Ambato.

.....
Ing. Msc. Vicente Morales L.
PRESIDENTE DEL TRIBUNAL

.....
Ing. Marco Jurado
DOCENTE CALIFICADOR

.....
Ing. Mario García
DOCENTE CALIFICADOR

DEDICATORIA

Dedico el presente trabajo a mis padres, Roberto Mejía y Nelly Bayas por sus palabras de aliento, que no dejaron que fracasará en momentos difíciles y por sus sabios consejos que me formaron como una gran persona con excelentes valores

A mi hermano: Ángel Mejía, el cual con su forma de ser me impulsó a seguir estudiando y demostrarles a todos que con esfuerzo y dedicación se puede conseguir todos los objetivos planteados

Tatiana Mejía

AGRADECIMIENTO

El presente trabajo va dirigido con una expresión de gratitud para Dios, por brindarme el conocimiento y la fortaleza para superarme cada día.

A mis padres, que con entero sacrificio, supieron entregar todo de sí, para que lograra culminar este proyecto. A mis amigos, compañeros que siempre nos ayudamos y compartimos a lo largo de la carrera universitaria.

Un agradecimiento especial a la Ing. María Gabriela Pérez, PhD, por su apoyo incondicional, sus sabios consejos, además de compartir sus conocimientos en el transcurso de este trabajo, gracias por brindarme la oportunidad de formar parte de su proyecto de investigación.

Al personal de la Unidad Oncológica SOLCA Tungurahua, en especial al Dr. Nalo Martínez, Director Médico y a la Dra. Aida Aguilar, por facilitarme su colaboración para la ejecución de este proyecto.

A la Universidad Técnica de Ambato en especial al personal y docentes de la Facultad de Ingeniería en Sistemas Electrónica e Industrial, por su apoyo. Al Ing. Mario García, por facilitarme su tiempo, conocimientos, además de su ayuda en la revisión y búsqueda de un tema para el desarrollo de la TEMI.

Tatiana Mejía

ÍNDICE GENERAL DE CONTENIDOS

| PRELIMINARES | PÁG. |
|--|-------------|
| TEMA | i |
| APROBACIÓN DEL TUTOR..... | ii |
| AUTORÍA DE LA TESIS | iii |
| APROBACIÓN DEL TRIBUNAL DE GRADO | iv |
| DEDICATORIA | v |
| AGRADECIMIENTO..... | vi |
| ÍNDICE GENERAL DE CONTENIDOS..... | vii |
| ÍNDICE DE FIGURAS..... | x |
| ÍNDICE DE TABLAS | xii |
| RESUMEN..... | xiii |
| ABSTRACT..... | xiv |
| GLOSARIO DE TÉRMINOS Y ACRÓNIMOS..... | xv |
| INTRODUCCIÓN | xvii |
| CAPÍTULO I..... | 1 |
| EL PROBLEMA | 1 |
| 1.1. Tema de investigación..... | 1 |
| 1.2. Planteamiento del problema..... | 1 |
| 1.3. Delimitación del problema..... | 3 |
| 1.4. Justificación..... | 3 |
| 1.5. Objetivos | 5 |
| 1.5.1. Objetivo general | 5 |
| 1.5.2. Objetivos específicos | 5 |
| CAPÍTULO II..... | 6 |
| MARCO TEÓRICO | 6 |
| 2.1. Antecedentes Investigativos..... | 6 |
| 2.2. Fundamentación Teórica..... | 7 |
| 2.2.1. Definición de termografía | 7 |
| 2.2.2. Cámara Termográfica..... | 8 |

| | |
|---|-----------|
| 2.2.3. Definición de Infrarrojos..... | 10 |
| 2.2.4. Definición de mamografía..... | 10 |
| 2.2.5. La mamografía digital vs mamografía convencional..... | 13 |
| 2.2.6. Mamografías en 3D..... | 13 |
| 2.2.7. Otras tecnologías utilizadas para la detección del cáncer de seno | 13 |
| 2.2.8. Herramientas software para imágenes digitales | 14 |
| 2.2.9. Introducción a la Visión Artificial | 15 |
| 2.2.9.1 Imagen digital..... | 16 |
| 2.2.10. Etapas del procesamiento digital de imágenes..... | 18 |
| 2.2.10.1. Adquisición de la imagen..... | 18 |
| 2.2.10.2. Pre-procesamiento de la imagen | 19 |
| 2.2.10.3. Segmentación | 25 |
| 2.2.10.4. Representación y Descripción..... | 31 |
| 2.2.10.5. Extracción de características | 31 |
| 2.2.10.6. Clasificación..... | 34 |
| 2.2.10.7. Métricas de evaluación..... | 39 |
| 2.3 Propuesta de Solución | 41 |
| CAPÍTULO III..... | 42 |
| METODOLOGÍA | 42 |
| 3.1. Modalidad de la investigación | 42 |
| 3.2. Población y Muestra..... | 42 |
| 3.3. Recolección de Información | 42 |
| 3.4. Procesamiento y análisis de los datos | 43 |
| 3.5. Desarrollo del proyecto | 43 |
| CAPÍTULO IV | 44 |
| DESARROLLO DE LA PROPUESTA | 44 |
| 4.1. Análisis de las imágenes de la base de datos utilizadas | 44 |
| 4.2. Método propuesto para el procesamiento digital de las imágenes termográficas | 45 |
| 4.2.1 Adquisición de las Imágenes Termográficas | 46 |
| 4.2.2 Segmentación Automática | 49 |

| | |
|---|-----------|
| 4.2.3 Pre-procesamiento de la imagen termográfica..... | 49 |
| 4.2.4 Definición de los descriptores de textura simples..... | 55 |
| 4.2.5. Segmentación de la región de interés..... | 59 |
| 4.2.6. Extracción de los descriptores de textura simple de la región de interés..... | 65 |
| 4.2.7. Clasificación..... | 66 |
| 4.2.8. Evaluación del clasificador..... | 69 |
| 4.3 Validación de los resultados..... | 71 |
| CAPÍTULO V..... | 75 |
| CONCLUSIONES Y RECOMENDACIONES..... | 75 |
| 5.1 Conclusiones..... | 75 |
| 5.2 Recomendaciones..... | 76 |
| REFERENCIAS..... | 77 |
| ANEXOS..... | 81 |
| Anexo A: Imágenes termográficas utilizadas..... | 81 |
| A.1 Listado de termogramas..... | 81 |
| A.2 Imágenes Test..... | 83 |
| A. 3. Certificado de la valoración de los resultados obtenidos por expertos médicos de la Unidad Oncológica SOLCA. | 86 |
| Anexo B: Manual de usuario del programa desarrollado..... | 87 |

ÍNDICE DE FIGURAS

| FIGURA | PÁG. |
|--|-------------|
| Fig. 2.1 Estructura de colores RGB. | 16 |
| Fig. 2.2 Esquema cartesiano de la imagen RGB..... | 17 |
| Fig. 2.3 Etapas fundamentales de un Sistema de Visión Artificial..... | 18 |
| Fig. 2.4 Máscara 3x3 utilizada por el filtro de la media | 24 |
| Fig. 2.5 Dilatación Morfológica..... | 28 |
| Fig. 2.6 Etapas de segmentación automática: detección de límites laterales, superiores e inferiores | 29 |
| Fig. 2.7 Aplicación del método Otsu y del Filtro Laplaciano | 30 |
| Fig. 2.8 Procedimiento para detectar límites superiores | 30 |
| Fig. 2.9 Resultado de separación de las mamas para la imagen IR_0225 | 31 |
| Fig. 2.10 Ejemplo de aplicación del algoritmo K-NN básico con K=3 | 37 |
| Fig. 2.11 Ejemplo de clasificación 1NN | 38 |
| Fig. 4.1 Diagrama de bloques del método propuesto para el procesamiento digital de las imágenes termográficas..... | 46 |
| Fig. 4.2 Imagen Termográfica TH4: Anormal | 47 |
| Fig. 4.3 Pre-procesamiento de la imagen de entrada. | 50 |
| Fig. 4.4 Mapeo disponible con el factor gamma..... | 51 |
| Fig. 4.5 Aplicación de la función imfilter en matlab. | 53 |
| Fig. 4.6 Implementación de la función fspecial en Matlab. | 54 |
| Fig. 4.7 Implementación de la función medfilt2 en matlab, | 55 |
| Fig. 4.8 Histograma normalizado de la imagen IR_4978 (ROI completo)..... | 60 |
| Fig. 4.9 Segmentación mediante im2bw con umbral 0.73..... | 61 |
| Fig. 4.10. Vecindad 4. | 61 |
| Fig. 4.11. Vecindad 8 | 61 |
| Fig. 4.12 Segmentación mediante máximos y mínimos regionales. | 63 |
| Fig. 4.13 Clasificación K-NN de la imagen IR_4978..... | 69 |
| Fig. B.1 Interfaz gráfica del programa desarrollado. | 87 |
| Fig. B.2. Opción botón Salir. | 88 |
| Fig. B.3. Interfaz del procesamiento de la imagen termográfica | 88 |
| Fig. B.4. Menú Imágenes | 89 |

| | |
|--|----|
| Fig. B.5. Menú Imágenes | 90 |
| Fig. B.6. Botón Realce | 90 |
| Fig. B.7. Filtro Simétrico | 91 |
| Fig. B.8. Filtro pasa alto..... | 91 |
| Fig. B.9. Filtro mediana | 92 |
| Fig. B.10. Filtro mediana | 92 |
| Fig. B.11. Gradiente | 93 |
| Fig. B.12. Segmentación por umbral=0.73 | 93 |
| Fig. B.13. Textura de la imagen..... | 94 |
| Fig. B.14. Máximas Temperaturas..... | 94 |
| Fig. B.15. Botón distancia..... | 95 |
| Fig. B.16. Guardar Imagen..... | 95 |
| Fig. B.17. Histograma ROI completo | 96 |
| Fig. B.18. Interfaz gráfica de características | 96 |
| Fig. B.19. Interfaz gráfica de características..... | 97 |
| Fig. B.20. Interfaz gráfica de características..... | 97 |
| Fig. B.21. Clasificación de la Imagen | 98 |
| Fig. B.22. Evaluación del clasificador | 99 |

ÍNDICE DE TABLAS

| TABLAS | PÁG. |
|---|-------------|
| Tabla 4.1 Requerimientos del software Matlab R2014a..... | 45 |
| Tabla 4.2 Descripción de los componentes utilizados en la construcción de la GUI | 48 |
| Tabla 4.3 Sintaxis y parámetro la función fspecial para construir los tipos de filtrado | 53 |
| Tabla 4.4 Conectividad bidimensional..... | 61 |
| Tabla 4.5. Imagen IR-4978 y algunos valores de media, desviación estándar, uniformidad y coeficiente de asimetría..... | 64 |
| Tabla 4.6 Medidas de calidad (Método I) | 71 |
| Tabla 4.7. Resultado de aciertos y fallos para casos normales y anormales utilizando K-NN (Método I)..... | 72 |
| Tabla 4.8. Resultado de aciertos y fallos para casos normales y anormales utilizando K-NN (Método II) | 72 |
| Tabla 4.9. Imágenes de test y algunos valores de media, desviación estándar, uniformidad y coeficiente de asimetría para el grupo normal | 73 |
| Tabla 4.10. Imágenes de test y algunos valores de media, desviación estándar, uniformidad y coeficiente de asimetría para el grupo anormal..... | 74 |
| Tabla A.1.1 Listado de termogramas utilizados..... | 81 |
| Tabla A.2.1 Imágenes Test, 9 con una alteración en las mamas y 9 saludables | 83 |

RESUMEN

El cáncer de mama es un problema de salud mundial que afecta principalmente a las mujeres y es una de las principales causas de muerte en los países desarrollados. La mayoría de los casos de cáncer son detectados en etapas avanzadas de la enfermedad, disminuyendo las expectativas de vida. El examen por excelencia para su diagnóstico es la mamografía, debido a que el cáncer de mama agrupa a diferentes variantes de la enfermedad, en algunos casos no se obtiene un diagnóstico acertado, ni tampoco se puede utilizar en mujeres menores de 40 años de edad, y ni en mujeres embarazadas. En la actualidad, se está introduciendo otras herramientas para detectar distintos tipos de enfermedades las cuales se consideran más efectivas para el diagnóstico precoz de cáncer de mama. La termografía, conocida también, como imágenes térmicas o imágenes de Infrarrojo es no invasiva, sin contacto, para detectar variaciones de temperatura en zonas donde pudiera existir un tumor, debido a que en estas regiones se presenta un aumento de temperatura, ocasionado por el flujo de sangre que necesita el tumor para crecer, pues el tejido precanceroso y zonas próximas al tumor su temperatura es siempre más altas que en el tejido normal de la mama.

Por ello, en este trabajo se propone el uso de los termogramas para detectar signos de cáncer de mama o anormalidades automáticamente, con alta precisión. Con el análisis y la segmentación de los mismos y el uso de los descriptores de texturas simples, se podrá detectar tempranamente la aparición de un tumor en las mamas en mujeres de cualquier edad con alguna densidad, tamaño y en mujeres embarazadas, lo cual reducirá la tasa de mortalidad debidas a esta enfermedad que se puede prevenir. Además se propone estimar las asimetrías en pechos sanos y cancerosos mediante el cálculo de diferentes parámetros de textura basadas principalmente, en los momentos del histograma para poder clasificar los termogramas en normales o anormales. El siguiente paso consistió en la segmentación de la ROI de la imagen mediante la técnica de umbralización. Para la clasificación de las imágenes en normal o anormal, se implementó un clasificador K-NN. Finalmente, para validar la eficacia de este método propuesto de detección se ha utilizado las métricas de exactitud, sensibilidad y especificidad.

ABSTRACT

Breast cancer is a global health problem that mainly affects women and is one of the leading causes of death in developed countries. Most cancers are detected in advanced stages of the disease, decreasing life expectancy. The test of choice for diagnosis is mammography, because breast cancer brings together different forms of the disease, in some cases not an accurate diagnosis is obtained, nor is it recommended for early detection in women under 40 years of age, and pregnant women. Currently, it is introducing other tools to detect different types of diseases and is postulated as most effective for early diagnosis of breast cancer technique. Thermography, also known as thermal infrared images or images is noninvasive, non-contact, to detect temperature variations in areas where there may be a tumor, because in these regions a temperature increase, caused by the flow occurs of blood needed to grow the tumor, precancerous tissue since areas around the tumor and its temperature is always higher than in normal breast tissue.

Therefore, in this paper the use of thermograms it is proposed to detect signs of breast cancer or automatically abnormalities with high accuracy. With the analysis and segmentation thereof and the use textures descriptors simple, is able detect early onset of breast tumor in women of any age with any density and size and in pregnant women, which will reduce the death rate from the disease that can be prevented. This work was estimated asymmetries in healthy and cancerous breasts by calculating different texture parameters based mainly in histogram moments to classify termogramas normal or abnormal. The next step was segmenting the ROI image by thresholding technique. For the classification of images by analyzing texture in normal or abnormal a K-Nearest Neighbor classifier (K-NN) was implemented. Finally, to validate the performance in recognition of the proposed detection method has use techniques accuracy, sensitivity and specificity, predictive positive rate (PDF) and predictive negative rate (PDN) of detection.

GLOSARIO DE TÉRMINOS Y ACRÓNIMOS

| | |
|--|---|
| Algoritmo | Es una lista bien definida, ordenada y finita de operaciones que permite hallar la solución a un problema. |
| Cáncer de mama | Cáncer que se forma en los tejidos de la mama, por lo general en los conductos (tubos que llevan leche al pezón) y los lobulillos (glándulas que producen leche). |
| Falsos Negativos (en inglés, <i>False Negative</i> (FN)) | es el número de incorrectas predicciones que en realidad son positivas |
| Falsos Positivos (en inglés, <i>False Positive</i> (FP)) | es el número de incorrectas predicciones que en realidad son negativas |
| Tasa de Falsos Negativos (en inglés, <i>False Positive Rate</i> (FPR)) | Define cuántos resultados positivos son incorrectos de entre todos los casos negativos disponibles durante la prueba |
| TN | Verdaderos Negativos (en inglés, <i>True Negative</i>): es el número de correctas predicciones que en realidad son negativas. |
| TP | Verdaderos Positivos (en inglés, <i>True Positive</i>), es el número de correctas predicciones que en realidad son positivas. |
| TPR | Tasa de Verdaderos Positivos. Mide hasta qué punto es capaz el clasificador de clasificar los casos positivos correctamente de entre todos los casos positivos |
| Gadolinio | Elemento químico de peso atómico 153. Nombre genérico atribuido a una serie de compuestos que llevan este elemento y se utilizan en resonancia magnética nuclear para mejorar las imágenes |
| GUIDE | Herramienta para la construcción de interfaces gráficas de usuario (en inglés, <i>Graphical User Interface Development Environment</i>) |
| GUIs | Interfaz gráfica de usuario (en inglés, <i>Graphical User Interfaces</i>) |
| INEC | Instituto Nacional de Estadísticas y Censo |
| IR | Infrarrojos; El infrarrojo es un tipo de luz que no podemos ver con nuestros ojos |
| K-NN | Vecino más cercano (en inglés, <i>K-Nearest Neighbor</i>). |
| Lobulillar | La glándula mamaria es un órgano destinado a la producción de la leche. Contiene de 15 a 20 lóbulos, ordenados radialmente, cada lóbulo está compuesto por lobulillos y durante la lactancia cada lobulillo termina en aproximadamente 100 pequeños bulbos llamados acinos o alveolos glandulares donde la leche es producida |
| Mama (en inglés, <i>breast</i>) | Órgano glandular ubicado en el pecho. La mama (seno) está formado por tejido conjuntivo, graso y tejido mamario que |

| | |
|-----------------------------|--|
| Microcalcificaciones | contienen glándulas que pueden producir leche materna Son minúsculas partículas de calcio localizadas en el seno y aparecen como pequeños puntos o manchas blancas en la imagen. Pueden aparecer solas o en grupo. La forma y tamaño de las microcalcificaciones ayudan al radiólogo a evaluar la probabilidad de que un cáncer esté presente |
| MRI | Imagen de Resonancia Magnética(en inglés, <i>magnetic resonance imaging</i>) |
| OMS | Organización Mundial de la Salud |
| OPS | Organización Panamericana de la Salud |
| PDI | Procesamiento digital de imágenes. Consiste en procesar las imágenes reales de manera digital por medio de un computador |
| PET | Tomografía por emisión de positrones. Es una nueva modalidad de diagnóstico por imagen, para el monitoreo de los procesos bioquímicos en el cuerpo humano |
| Píxel | Acrónimo formado con las palabras inglesas 'Picture' 'element'. Es el elemento simple de una imagen digital. |
| PNBV | Plan Nacional del Buen Vivir |
| RGB | Modelo de color Red/Green/Blue, Rojo, Verde, Azul |
| ROI | Región de Interés (en inglés, <i>Region Of Interest</i>) |
| TC | Tomografías Computarizadas para producir imágenes de las estructuras internas del cuerpo. |
| Tamizaje o cribado | Es la aplicación sistemática de pruebas de tamizaje en una población aparentemente asintomática. Su objetivo es detectar a las personas que presenten anomalías indicativas de cáncer. |

INTRODUCCIÓN

El cáncer de mama es el más frecuente en las mujeres tanto en los países desarrollados como en los países en desarrollo. Aunque existen estrategias de prevención, dichas medidas no pueden eliminar la mayoría de los casos de cáncer de mama que se dan en los países de ingresos bajos y medios, donde el diagnóstico se realiza en fases muy avanzadas. Así pues, la detección precoz con vistas a mejorar el pronóstico y la supervivencia de esos casos sigue siendo la piedra angular del control del cáncer de mama (Anderson et al., 2008).

Las estrategias de detección precoz recomendadas para los países de ingresos bajos y medios son el conocimiento de los primeros signos y síntomas, y el cribado basado en la exploración clínica de las mamas en zonas de demostración. El cribado mediante mamografía es muy costoso y se recomienda para los países que cuentan con una buena infraestructura sanitaria y pueden costear un programa a largo plazo. En el mundo desarrollado, los cánceres de mama y de cuello uterino son la principal causa de muerte entre las mujeres. En la mayor parte de Asia, América Latina y algunos países africanos, las muertes por estos dos tipos de cáncer superan en número a las muertes relacionadas con el embarazo [1].

Los métodos de detección precoz actuales son, el diagnóstico precoz o el conocimiento de los primeros signos y síntomas en la población sintomática, para facilitar el diagnóstico, además del tratamiento temprano, y el cribado, es decir, la aplicación sistemática de pruebas de tamizaje en una población aparentemente asintomática. La selección como objetivo de grupos de edad inadecuados, por ejemplo mujeres jóvenes con bajo riesgo de cáncer de mama, puede traducirse en una disminución del número de cánceres detectados por mujer sometida a cribado, y reducir así la costoeficacia de la medida. Además, esa focalización en las mujeres más jóvenes obligaría a analizar más tumores benignos y provocaría una sobrecarga innecesaria de los servicios de salud, por los recursos diagnósticos adicionales que entrañaría (Yip et al., 2008).

La mamografía es la herramienta estándar por excelencia para la detección precoz del cáncer de mama, pero el rendimiento de este procedimiento es bajo en mujeres más jóvenes

y es debido a la dificultad de formación de imágenes en presencia de tejido mamario denso (Wishart et al., 2010) [2]. Existen otras opciones para realizar pruebas mamarias que son más eficaces y seguras. La termografía, conocido también como imágenes térmicas o imágenes de Infrarroja es no invasivo, sin contacto, que mide la temperatura corporal a partir de la radiación Infrarroja, que de forma natural emite el cuerpo. Es pasiva, indolora, rápida y de bajo costo y un método sensible [3]. El uso de la termografía se basa en el principio de que la actividad metabólica y la circulación vascular ambas en tejido precanceroso y sus alrededores de un cáncer de mama en desarrollo son casi siempre mayores que en tejido normal de la mama Fok et al. [4]. Debido a la sensibilidad de la termografía, los primeros signos de cáncer de mama se puede observar en el espectro de temperaturas.

Por ello, la termografía es una herramienta de diagnóstico para detectar diversas enfermedades. Muchos autores (Ng [3]; Ng y Chen [5]; Ng et al. [6]; Ng y Sudharsan [7]; EtehadTavakol et al. [8]; EtehadTavakol y Ng [9]; Jakubowska et al. [10]; Sowmya y Bhattacharya [11]; Pakhira [12]) propusieron métodos para segmentar los termogramas y detectar las regiones calientes y los tejidos potencialmente sospechosos de dichas imágenes.

Tan et al. [13] propusieron el uso de características de textura para estudiar los termogramas oculares en sujetos jóvenes y ancianos. Acharya et al. [14] usaron características de textura y un clasificador SVM para detectar signos de cáncer de mama, con 36 imágenes para el entrenamiento y 14 termogramas para las pruebas, la precisión de la clasificación reportada fue de 88,1%. En Ng et al.[15] mencionan que el resultado de la termografía podría corregirse 8-10 años antes que la mamografía para detectar una masa. Keyserlingk et al. [16] reportaron que el tamaño medio de los tumores detectados por la termografía es 1,28 cm, mientras que 1,66 cm por mamografía.

El análisis y la segmentación de los termogramas mediante descriptores de textura simples, ayudará al diagnóstico precoz de cáncer de mama en el hospital SOLCA Tungurahua. Así, las características de textura propuesta en esta TEMI están basadas en los momentos del

histograma para la clasificación de dichas imágenes como normales o anormales. En el paso de la segmentación de la imagen, se ha utilizado las técnicas de umbralización y de morfología matemática. En el paso de la evaluación de la clasificación del método basado en el análisis de las texturas propuestas, se implementó un clasificador k-NN (K-vecino más cercano). Finalmente, para evaluar el rendimiento del clasificador se ha utilizado las técnicas de exactitud, sensibilidad y especificidad obtenidas a partir de la matriz de confusión

La organización de este trabajo se ha estructurado en capítulos.

Así, el Capítulo I, presenta el problema de investigación, sus consecuencias a nivel mundial, nacional, las personas involucradas en el proyecto, además delimita su contenido en espacio y tiempo, incluye el objetivo general, así también los objetivos específicos del proyecto.

El Capítulo II, presenta los conceptos, las definiciones de la termografía, así como las diferentes técnicas para detectar cáncer de seno, además las etapas del procesamiento digital de imágenes de Gonzales y Woods (1996) [17], el algoritmo K-NN (*K-Nearest Neighbor*), así también la evaluación del clasificador.

El Capítulo III, establece la metodología, las modalidades de investigación efectuadas en el proyecto, incluye la muestra, herramientas para la recolección de información y distribución de tiempo para la ejecución de la investigación.

El Capítulo IV, presenta el desarrollo de la propuesta para el análisis y segmentación de imágenes termográficas mediante descriptores de textura simples, en este caso el diseño de una interfaz gráfica GUI implementada en matlab, basada en las etapas del procesamiento digital de imágenes de Gonzales y Woods (1996) [17]

El Capítulo V, presenta las conclusiones de los resultados obtenidos y recomendaciones planteados en esta tesis. Finalmente, se presenta la lista de referencias consultadas y los anexos.

CAPÍTULO I

EL PROBLEMA

1.1. Tema de investigación

Segmentación y análisis de imágenes termográficas mediante descriptores de textura simples

1.2. Planteamiento del problema

Mediante estadísticas publicadas por la Organización Mundial de la Salud (OMS) a nivel mundial se han obtenido los siguientes datos y cifras. El cáncer de mama es el más común entre las mujeres en todo el mundo, representa el 16% de todos los cánceres femeninos. Se estima que en 2004 murieron 519.000 mujeres por cáncer de mama y, aunque este cáncer está considerado como una enfermedad del mundo desarrollado, la mayoría (69%) de las defunciones por esa causa se registran en los países en desarrollo.

Las tasas de supervivencia del cáncer mamario varían en todo el mundo, desde el 80% o más en América del Norte, Suecia y Japón, pasando por un 60% aproximadamente en los países de ingresos medios, hasta cifras inferiores al 40% en los países de ingresos bajos. Las bajas tasas de supervivencia observadas en los países poco desarrollados pueden explicarse principalmente por la falta de programas de detección precoz, que hace que un alto porcentaje de mujeres acudan al médico con la enfermedad ya muy avanzada, pero también por la falta de servicios adecuados de diagnóstico y tratamiento. [18]

De acuerdo con la Oficina del Censo de EE.UU., 50.5 millones de estadounidenses, es decir un total del 16% de la población de EE.UU., se identificaron como hispanos o latinos

en 2010. Los términos “hispano” y “latino” se usan para referirse a las personas de origen hispano. La palabra “hispano” es una designación federal de EE.UU. que se usa en los sistemas nacionales y estatales de reporte. La tasa de incidencia de cáncer de seno entre las mujeres hispanas es 26% menor que la de las mujeres blancas no hispanas.

En el año 2010 en los Estados Unidos, 206.966 mujeres y 2.039 hombres recibieron un diagnóstico de cáncer de mama, de los cuales, 40.996 mujeres y 439 hombres murieron por causa de esta enfermedad. En Brasil, actualmente el número de casos nuevos de cáncer de mama anuales es aproximadamente de 49.000 [19]. En Ecuador las estadísticas realizadas por el Instituto Nacional de Estadísticas y Censo (INEC) señalan que en 2011, 419 mujeres murieron a causa del cáncer de mama, mientras 713, casi el doble, por cáncer de estómago. Quito es la ciudad con mayor incidencia de cáncer de mama, pues 36 de cada 100.000 quiteñas fueron diagnosticadas con este tipo de cáncer entre 2008 y 2011, registrando un total de 890 casos en tres años. [20]

Con el uso de imágenes térmicas se podrá extraer automáticamente ciertos descriptores relevantes a partir de las imágenes que permitan reconocer ciertas patologías mamarias en sus etapas iniciales. Las imágenes térmicas permiten así poder analizar los gradientes de temperatura observados en las regiones afectadas de las pacientes que presentan, en nuestro caso, patologías mamarias en su estado precoz. De esta forma, la región afectada puede ser detectada más fácilmente. [3]

A pesar del gran avance tecnológico que representan las cámaras de infrarrojo, estas no sirven para realizar un diagnóstico por si solas, lo que es relevante en estos casos es la medida de la temperatura que se puede obtener y compararla con la temperatura normal que se debería estar observando.

Así, se considera recomendable que las mujeres de 40 años o más se hagan mamografías de detección cada uno o dos años. Hacerse una mamografía de forma habitual puede reducir el riesgo de morir de cáncer de mama. [18]

1.3. Delimitación del problema

Área Académica: Comunicaciones

Líneas de Investigación: Tecnologías de Comunicación

Sublíneas de Investigación: Procesamiento digital de señales e imágenes

Delimitación espacial: La investigación se realizó en la Provincia de Tungurahua en el Hospital SOLCA

Delimitación temporal: La investigación se desarrolló en 6 meses a partir de la aprobación del Honorable Consejo Directivo de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial.

1.4. Justificación

El cáncer de mama es una anomalía del tejido mamario que cada año se lleva la vida de 4.000 mujeres en Ecuador, según datos de la OMS. Según esta organización, en el mundo se presentan alrededor de 500.000 nuevos casos de cáncer por año y se producen alrededor de 250.000 muertes por esa causa. Del mismo modo, en Ecuador se presentan cerca de 10.200 nuevos casos por año y mueren unas 4.000 mujeres.

Los datos que arroja la Organización Panamericana de la Salud (OPS) dibujan un panorama cuanto menos preocupante: El cáncer de mama es la primera causa de muerte en Ecuador, con un 35,4%, seguido del cáncer de piel, con un 32%. En Quito las cifras aumentan: ocho de cada 100 mujeres de entre 25 y 64 años mueren por esta causa, según un informe del INEC. [20]

Por ello, el principal objetivo del presente proyecto es desarrollar algoritmos que ayude al especialista radiólogo, a poder detectar automáticamente las lesiones utilizando técnicas de análisis de imágenes termográficas en mamografías y de los patrones representativos como son calcificaciones, nódulos, entre otros. Mediante este proyecto se beneficia el Hospital SOLCA y sus médicos, ya que darán una mejor atención a pacientes con signos de

enfermedad de cáncer de mama para ser detectada, tratada, prevenir a tiempo y disminuir el alto índice de mortalidad por causa de este tipo de cáncer, además de ello fortalecerá los vínculos de investigación entre distintas instituciones universitarias y el Hospital SOLCA, pues los miembros que participarán en este proyecto pertenecen a la Universidad Técnica de Ambato (Ecuador), la Universidad Fluminense de Brasil y la Universidad Rey Juan Carlos (España).

Los resultados del proyecto se podrían usar para dar atención a problemas o necesidades locales, como es el caso del diagnóstico precoz de patologías mamarias usando imágenes térmicas. En relación con el Plan Nacional del Buen Vivir (PNBV) para el periodo 2013-17, este proyecto está más directamente relacionado con los siguientes objetivos:

- Objetivo nº 2: “Auspiciar la igualdad, la cohesión, la inclusión y la equidad social y territorial en la diversidad”
- Objetivo nº 3: Mejorar la calidad de vida de la población

A continuación, se señalan algunos datos oficiales actuales en relación con la incidencia del cáncer de mama proporcionados por SOLCA, bajo el título (**detección temprana del cáncer debe basarse en la realidad epidemiológica del país**), presentado durante el V Congreso Nacional de Oncología, con aportación de datos reales sobre la incidencia del cáncer de mama para orientar mejor las acciones de detección temprana- “Un programa de tamizaje debe ser basado en la realidad epidemiológica de cada país. Consideran que se debe identificar a las mujeres en alto riesgo y someterlas a tamizaje de acuerdo al caso”. [21]

Las nuevas tecnologías de tamizaje son un paso importante en la lucha contra el cáncer de mama, muchos investigadores están buscando alternativas a la mamografía. Las nuevas tecnologías de termografía no pierden efectividad con tejido mamario denso, disminuyendo las posibilidades de resultados falsos negativos, son también importantes. [22]

En el 96% de los casos, el cáncer de mama es tratable si se detectan a tiempo. Si bien las medidas como el autoexamen pueden alertar sobre la presencia de tumores, generalmente para cuando son palpables ya tienen un tamaño considerable. Las estadísticas indican que el

52% de las mujeres afectadas acuden al hospital en etapas tempranas, lo cual aumenta la probabilidad de salvar su vida.

De acuerdo a los Registros de Tumores de SOLCA, encargados de investigar los casos nuevos de cáncer en el Ecuador (basados en las normas y codificaciones internacionales), entre 2006 y 2008 la mayor tasa de incidencia de cáncer de mama, en mujeres, se registró en Quito. 36 de cada 100.000 quiteñas fueron diagnosticadas con este tipo de cáncer; un total de 890 casos en tres años. La menor incidencia se registró en Portoviejo, donde 17 de cada 1000.000 mujeres presentó esta patología. [20][23]

1.5. Objetivos

1.5.1. Objetivo general

Segmentar y determinar los descriptores de textura que permitan la clasificación de patrones en imágenes térmicas.

1.5.2. Objetivos específicos

- Analizar las imágenes de la base de datos utilizadas o las proporcionadas por SOLCA.
- Mejorar la imagen para quitar artefactos presentes en las mismas
- Definir los algoritmos para la obtención de los descriptores.
- Segmentar la imagen
- Extraer los descriptores de textura simple en la región de interés (ROI) obtenido durante la segmentación.
- Validar los resultados con los diagnósticos proporcionados por el especialista médico

CAPÍTULO II

MARCO TEÓRICO

2.1. Antecedentes Investigativos

Dado la novedad de la técnica, es oportuno aclarar que en este entorno y en el país, no se cuenta con trabajos similares al respecto, pero se apoyará en algunos trabajos recientes existentes en la literatura y que servirán como referencia para el desarrollo de este trabajo y son los siguientes:

Según María Yaneli Ameca Alducin, en su proyecto Validación Cuantitativa de Información Termográfica para el Pre-diagnóstico de Cáncer de Mama, enfatiza que la termografía mamaria es una técnica complementaria que ha sido retomada en los últimos años porque se han demostrado sus potencialidades como auxiliar a las técnicas de pre-diagnóstico ya existentes, y concluye una de las ventajas de la termografía son los bajos costos empleados en la realización del estudio y la portabilidad para poder llegar a lugares inaccesibles para otras técnicas de pre-diagnóstico. Podría ser utilizada como método de pre-diagnóstico, debido que si indica que se tiene cáncer es muy probable que eso sea dado a su alta sensibilidad. [24]

En el XVIII Congreso Argentino de Bioingeniería SABI 2011 - VII Jornadas de Ingeniería Clínica Mar del Plata, los autores: J Massa, P. Escobar, M. Del Fresno, M. Santiago, E. Arguñarena, en su trabajo realizaron la Segmentación y caracterización en imágenes termográficas para diagnóstico de lesiones mamarias, en la misma que menciona la aplicación de la termografía como técnica de imagen complementaria a la mamografía y a

la ecografía mamaria posee múltiples ventajas como la no invasividad, el bajo costo, la visualización inmediata sin necesidad de un receptor de imagen. Demuestra ser especialmente útil en la exploración de zonas sensibles a la radiación y donde la ecografía es insuficiente o poco práctica a raíz de sus propias limitaciones. Para trabajos futuros un estudio de correlación entre información diagnóstica aportada por los profesionales médicos y la información cualitativa que brindan los algoritmos. [25]

2.2. Fundamentación Teórica

2.2.1. Definición de termografía

La Termografía infrarroja es una técnica que permite ver la temperatura de una superficie con precisión sin tener ningún contacto con ella. Gracias a la Física podemos convertir las mediciones de la radiación infrarroja en mediciones de temperatura, esto es posible midiendo la radiación emitida en la porción infrarroja del espectro electromagnético desde la superficie del objeto, convirtiendo estas mediciones en señales eléctricas. Mediante la captación de la radiación infrarroja del espectro electromagnético, utilizando cámaras termográficas o de termovisión. [26]

Termografía mamaria

La termografía mamaria es una técnica de pre-diagnóstico mediante imágenes térmicas de las mamas, la cual ayuda en la detección temprana de cáncer de mama. La imagen de infrarrojos (IR) de la mama, también conocida como termografía de mama, es un estudio no invasivo e indoloro, no expone al paciente a radiación ionizante, en la que se mide la respuesta fisiológica de la mama, con esto nos referimos específicamente a los cambios de temperatura. Este estudio se basa en la diferencia entre las temperaturas. Cuando una mama está enferma los tumores malignos o benignos necesitan más irrigación de sangre y esto conlleva a un aumento de temperatura con respecto a una mama sana. [27, 28]

Termografía

Es la técnica de monitoreo remoto que permite la medición de temperaturas y la formación de imágenes térmicas (llamadas Termogramas), de un cuerpo, componente, equipo o proceso, a partir de la Radiación Infrarroja, que en forma natural emiten los mismos.

La radiación del cuerpo es una función

La energía térmica o infrarroja es luz no visible, es decir, la parte del espectro electromagnético que se percibe como calor. A diferencia de la luz visible, en el mundo infrarrojo todo aquello con una temperatura sobre cero absoluto emite calor; incluso, los objetos muy fríos, tales como cubos de hielo, emiten luz infrarroja. Los rayos infrarrojos permiten ver lo que los ojos no pueden.

La relación entre la energía irradiada por un objeto (R) y su temperatura se describe por la ley de *Stefan-Boltzmann* (Ecuación 2.1):

$$R = A \epsilon \sigma T^4 \quad (2.1)$$

donde la radiación infrarroja (R) está directamente relacionada con el área del objeto (A), epsilon (ϵ), es una propiedad de la superficie del objeto enfocado llamada “emisividad” y la constante de *Stefan-Boltzmann* (σ) es la cantidad de radiación y la cuarta potencia de su temperatura absoluta (T).

2.2.2. Cámara Termográfica

Los termogramas se adquieren mediante una cámara termográfica que es sensible a la radiación infrarroja. Una cámara termográfica registra la intensidad de la radiación en la zona infrarroja del espectro electromagnético y la convierte en una imagen visible. A mayor cantidad de calor en cada punto de la superficie del objeto mayor intensidad de radiación emite dicho punto, por lo que el “mapa de calor” que proporciona la cámara termográfica distinguirá tantos puntos como su resolución le permita y con una diferencia de calor tan pequeña como su sensibilidad.

Funcionamiento de la Cámara Termográfica

La energía de infrarrojos que irradia un objeto se enfoca con el sistema óptico sobre un detector de infrarrojos. El detector envía los datos al sensor electrónico para procesar la imagen. Y el sensor traduce los datos en una imagen, compatible con el visor y visualizable en un monitor de vídeo estándar o una pantalla LCD. La termografía de infrarrojos es el arte de transformar una imagen de infrarrojos en una imagen radiométrica que permita leer los valores de temperatura. Por tanto, cada píxel de la imagen radiométrica es, de hecho, una medición de temperatura. Para ello, se incorporan complejos algoritmos a la cámara de infrarrojos. Esto hace de la cámara termográfica una herramienta perfecta para el mantenimiento predictivo.

La radiación registrada por la cámara termográfica consiste en la radiación de onda larga emitida, reflejada y transmitida que surge de los objetos presentes en el campo de visión de la cámara.

Emisividad (ϵ) es la medida de la capacidad de un material de emitir (propagar) radiación infrarroja. La ϵ varía según las propiedades de la superficie, el material, y, (para algunos materiales) según la temperatura del objeto medido. La emisividad máxima es $\epsilon = 1$ (100%), la cual no se da, para cuerpos reales $\epsilon < 1$, porque los cuerpos reales también reflejan y algunos incluso transmiten radiación. La ϵ se puede configurar manualmente en la cámara, para el caso de imágenes del cuerpo humano se debe tener en cuenta la emisividad de la piel de una persona de raza blanca y negra

Reflexión (ρ) es la medida de la capacidad de un objeto de reflejar la radiación infrarroja. La ρ depende de las propiedades de la superficie, la temperatura y el tipo de material. La temperatura de la radiación reflejada se puede configurar manualmente en la cámara termográfica (RTC). En varias aplicaciones, la RTC corresponde con la temperatura ambiente

Transmisión (τ) es la medida de la capacidad de un material de transmitir (permitir el paso) de la radiación infrarroja. La τ depende del tipo y grosor del material. La radiación

infrarroja registrada por la cámara termográfica consiste en: la radiación emitida por el objeto medido; la reflexión de la radiación ambiente y la transmisión de radiación del objeto medido como se indica en la Ecuación 2.2. El resultado de la suma de estos factores es siempre 1 ($\cong 100\%$), esta ecuación se denomina Ley de radiación de *Kirchhoff's*

$$\varepsilon + \rho + \tau = 1 \quad (2.2)$$

La variable τ se omite en la fórmula debido a que su valor es insignificante, reduciendo dicha ecuación en la siguiente expresión (Ecuación 2.3) [30]:

$$\varepsilon + \rho = 1 \quad (2.3)$$

2.2.3. Definición de Infrarrojos

El infrarrojo es un tipo de luz que no podemos ver con nuestros ojos. Están a medio camino entre el espectro visible y las microondas del espectro electromagnético. La fuente principal de radiación de infrarrojos es el calor o la radiación térmica. Cualquier objeto con una temperatura superior al cero absoluto ($-273,15\text{ }^\circ\text{C}$ o $0\text{ }^\circ\text{Kelvin}$) emite radiación en la región infrarroja. Hasta los objetos más fríos como los cubitos de hielo, emiten rayos infrarrojos.

Radiación Infrarroja

La radiación infrarroja, o radiación IR es un tipo de radiación electromagnética y térmica, de mayor longitud de onda que la luz visible, pero menor que la de las microondas. Consecuentemente, tiene menor frecuencia que la luz visible y mayor que las microondas. Su rango de longitudes de onda va desde unos 0,7 hasta los 1000 micrómetros. La radiación infrarroja es emitida por cualquier cuerpo cuya temperatura sea mayor que 0 Kelvin, es decir, $-273,15$ grados Celsius (cero absoluto). [31]

2.2.4. Definición de mamografía

La mamografía es una imagen radiográfica que emplea bajas dosis de rayos X para examinar la glándula mamaria, sin la utilización de medios de contraste. La mamografía indica diferentes elementos como el tejido mamario glandular, el tejido graso y la piel.

Esta técnica consiste en colocar la mama entre dos placas y presionarla durante unos segundos mientras se realizan las radiografías. No hay ningún peligro por las radiaciones de esta técnica, ya que son de baja potencia.

Este estudio, aunque es la técnica por excelencia utilizada como pre-diagnóstico, tiene sus inconvenientes. Es difícil detectar irregularidades en mamas jóvenes, debido a que el tejido es denso; también se dificulta cuando se tienen implantes, si se tiene una sola mama, poder dar un pre-diagnóstico se ve afectado, porque para hacerlo se utiliza la comparación con la otra mama. [32]

Mamografía selectiva de detección y una mamografía de diagnóstico

La mamografía selectiva de detección es una radiografía del seno, se emplea para detectar cambios en el tejido mamario; es posible detectar microcalcificaciones, las cuales, indican la presencia de cáncer de seno en mujeres que no presentan signos o síntomas de la enfermedad. Las mamografías selectivas de detección pueden ayudar a reducir el número de muertes por cáncer de seno entre mujeres de 40 a 70 años de edad.

La mamografía de diagnóstico es una radiografía del seno, mediante un examen radiológico exhaustivo para obtener una imagen más clara y detallada de cualquier área anormal que se visualiza en la mamografía de detección. Ayudan al médico a conocer sobre cambios extraños en las mamas, como engrosamiento, secreción del pezón, cambio en el tamaño o forma del seno; así también, abultamiento u otro signo o síntoma de la enfermedad

Las mamografías de diagnóstico requieren más tiempo que las mamografías selectivas de detección porque se necesitan más radiografías para obtener vistas del seno desde varios ángulos. El técnico puede amplificar una zona sospechosa para producir una imagen detallada que ayude al médico a hacer un diagnóstico preciso. [33]

Beneficios de las mamografías selectivas de detección

La detección temprana de cáncer de seno con la mamografía selectiva de detección significa que el tratamiento puede empezarse más pronto en el curso de la enfermedad, posiblemente antes de que se haya extendido. Los resultados de estudios clínicos aleatorizados y de otros estudios indican que la mamografía de detección puede ayudar a reducir el número de muertes por cáncer de seno entre mujeres de 40 a 70 años de edad, especialmente para las que tienen más de 50 años de edad. Sin embargo, los estudios llevados a cabo hasta la fecha no han indicado que haya un beneficio de las mamografías de detección regulares en mujeres menores de 40 años de edad o de mamografías de detección como base (mamografías que se usan como punto de comparación) que se toman antes de los 40 años de edad. [34]

Resultados negativos falsos. Los resultados negativos falsos suceden cuando los senos están formados tanto de tejido denso (es decir, tejido glandular y tejido conjuntivo, lo cual en conjunto se conoce como tejido fibroglandular) como de tejido adiposo. El tejido adiposo aparece de color oscuro en las mamografías, mientras que el tejido fibroglandular (tejido conectivo y glandular) aparece como zonas blancas. Ya que el tejido fibroglandular y los tumores tienen una densidad semejante, puede ser más difícil detectar los tumores en mujeres con senos más densos. Los resultados negativos falsos ocurren con más frecuencia entre mujeres jóvenes que entre mujeres de mayor edad ya que las mujeres jóvenes tienen más probabilidad de tener senos densos. Conforme envejece la mujer, sus senos se hacen, en general, más grasos, por lo que son menos probables los resultados negativos falsos. Los resultados negativos falsos pueden conducir a que se retrase el tratamiento y a generar un sentido falso de seguridad en las mujeres afectadas. [35]

Resultados positivos falsos. Los resultados positivos falsos ocurren cuando los radiólogos concluyen que las mamografías son anormales pero en realidad no hay cáncer presente. Después de toda mamografía anormal se deberán hacer pruebas adicionales (mamografías de diagnóstico, ecografías, una biopsia) para determinar la presencia de cáncer.

2.2.5. La mamografía digital vs mamografía convencional

La mamografía digital es un sistema de mamografía; en el cual, la película de rayos x es reemplazada por detectores de estado sólido que convierten los rayos X en señales eléctricas. Aunque todavía se utiliza la radiación, la mamografía digital requiere una dosis mucho más pequeña. Las señales eléctricas se utilizan para producir imágenes que pueden ser manipulados electrónicamente, un médico puede acercar la imagen, ampliar y optimizar las diferentes partes del tejido del seno sin tener que tomar una imagen adicional.

La mamografía convencional utiliza sistemas de pantalla-película (*film screen mammography*) cuyo mecanismo de acción consiste en el paso a través del tejido mamario del haz de rayos X, el cual incide sobre la pantalla provocando una reacción química en la película que se procesa y se muestra como una imagen en escala de grises . Aunque se obtiene una imagen de alta resolución, al no acompañarse de un adecuado contraste, algunas lesiones podrían no detectarse. Es por esto por lo que la mamografía convencional no detecta todos los cánceres de mama y presenta una sensibilidad limitada en la detección de tumores en mujeres con mamas radiográficamente densas. Por otro lado, la imagen obtenida no puede modificarse y su transmisión y almacenamiento genera problemas. [36]

2.2.6. Mamografías en 3D

Las mamografías tridimensionales (3D), también conocidas como tomosíntesis del seno, son un tipo de mamografía digital en la que se usan máquinas de rayos X para tomar imágenes de rebanadas delgadas del seno desde diferentes ángulos y un programa de computadora se usa para reconstruir una imagen. Este proceso es similar al que usa el escáner de las tomografías computarizadas (TC) para producir imágenes de las estructuras internas del cuerpo.

2.2.7. Otras tecnologías utilizadas para la detección del cáncer de seno

Los esfuerzos para mejorar la mamografía convencional incluyen exploraciones de mamografía digital, resonancia magnética (MRI), tomografía por emisión de positrones

(PET), y la tomografía óptica difusa, la cual utiliza luz en lugar de rayos X para crear imágenes del seno. [37]

Resonancia magnética

La resonancia magnética con contraste con gadolinio muestra una descripción más extensa de la enfermedad (extensión local del tumor, presencia de lesiones no detectadas o accidentales) cuando hay discrepancias entre el examen clínico, la mamografía y los ultrasonidos, para así planificar mejor el tratamiento. Además, se utiliza para mujeres con cáncer invasivo si la densidad mamaria impide una evaluación mamográfica adecuada y para mujeres con cáncer lobulillar invasivo donde se considere la cirugía conservadora [35]. En estos casos ofrece una sensibilidad de 91 a 100%.

Tomografía por emisión de positrones (PET)

La tomografía por emisión de positrones (PET) es una nueva modalidad de diagnóstico por imagen que sin lugar a dudas a llegado a ser una poderosa herramienta científica y clínica para el monitoreo de los procesos bioquímicos en el cuerpo humano principalmente.

Las aplicaciones del estudio PET en el diagnóstico e investigación de las enfermedades permite el estudio de la cuantificación in vivo del metabolismo del tejido local, su bioquímica así como su farmacología. Consiste en la detección, visualización y cuantificación de la distribución radiactiva del radionúclido emisor de positrones, los cuales son retenidos de forma selectiva como trazadores, en los sistemas biológicos bajo el estudio. [38]

2.2.8. Herramientas software para imágenes digitales

MATLAB

MATLAB (*MATrix LABoratory*) es un lenguaje de alto nivel que incorpora herramientas de cálculo numérico y visualización. Es un programa de *Mathworks* para realizar todo tipo de cálculos con vectores y matrices. Además presenta la posibilidad de realizar gráficos en

dos y tres dimensiones. Además es un programa muy potente que realiza con gran precisión operaciones complejas. Se emplea en todo tipo de investigaciones donde se trabaja con funciones matemáticas o matrices de puntos. Su entorno gráfico es simple y su aprendizaje no requiere gran esfuerzo.

Para el procesamiento de las imágenes se ha utilizado herramientas tales como, el entorno de programación MATLAB para trabajar con matrices de forma más sencilla, y su *Image Processing Toolbox*, *Statistics Toolbox*, *Signal Processing Toolbox* y el *GUIDE*, entre otras librerías incluidas en la misma. Programas de usuario: *PhotoShop*, *Paint Shop Pro*, *Gimp*, *Irfranwiev*. Además de las anteriores se utiliza el software *FLIR* v. 9.0 para la generación de los reportes de las imágenes analizadas. [39]

2.2.9. Introducción a la Visión Artificial

La visión artificial o también conocida visión por computadora, es un conjunto de técnicas, encaminadas a resolver problemas relacionados con la visión humana tales como la clasificación, el seguimiento, la identificación y la descripción de objetos, entre otras.

Por tanto, la visión artificial se define como los procesos de obtención, caracterización e interpretación de información de imágenes tomadas de un mundo tridimensional que generalmente conlleva los siguientes pasos [40]:

- Adquisición de imágenes es el proceso de obtención de la imagen para posteriormente extraer las características más relevantes.
- Sistema de iluminación que proporcione condiciones uniformes e independientes del entorno para facilitar la extracción de rasgos de interés para una determinada aplicación.
- Procesado e interpretación de resultados desarrollado mediante un conjunto de algoritmos y transformaciones necesarias para realizar el análisis y extracción de las características en una imagen. [41]

2.2.9.1 Imagen digital

Una imagen digital puede definirse como una función bidimensional $f(x, y)$ donde x, y son coordenadas en el plano y la amplitud f es llamada intensidad o nivel de gris en ese punto [42].

Cuando (x, y) y f son todos finitos (cantidades discretas) llamamos a la función como imagen digital. Es decir, una imagen digital está compuesta por un número finito de elementos llamados píxeles, cada uno de los cuales con un valor y una posición particular

El valor es relativo a alguna propiedad del punto que representa, como por ejemplo su brillo o su matiz. El término píxel (abreviación de *Picture Element* o elemento de imagen), se trata de la unidad mínima de información de una imagen, la cual aparece como un punto en la pantalla o en una impresora. En realidad cada píxel se compone de tres registros de color, mediante la combinación de cierta cantidad de rojo, verde y azul, el píxel adopta un color particular que se indica en la Fig. 2.1 [43].




Fig. 2.1 Estructura de colores RGB. (Tomado de: [43])

TIPOS DE IMÁGENES DIGITALES

En el procesamiento digital de imágenes (PDI) se maneja cuatro tipos de imágenes básicamente: imágenes RGB, imágenes indexadas, imágenes en escala de grises e imágenes binarias. Las cuales que se detallan a continuación:

- **IMÁGENES RGB (RED-GREEN-BLUE).** - Una imagen de color RGB es una matriz de $M \times N \times 3$ píxeles de color. Está basado en un sistema de coordenadas cartesianas que forman un cubo, en sus 3 esquinas están los valores RGB (rojo (R), verde (G) y azul (B)). En las restantes 3 esquinas del cubo se encuentran los valores

de cian, magenta y amarillo; en el origen está el color negro como también en el vértice más alejado del color negro se encuentra el color blanco como se visualiza en la Fig. 2.2. Utilizan 8 bits por canal (8 bits x 3), es decir, 24 bits de color para cada píxel. Reproducen hasta 16,7 millones de colores. Además soporta algunos formatos como: JPG, BMP, PNG, etc. [42]

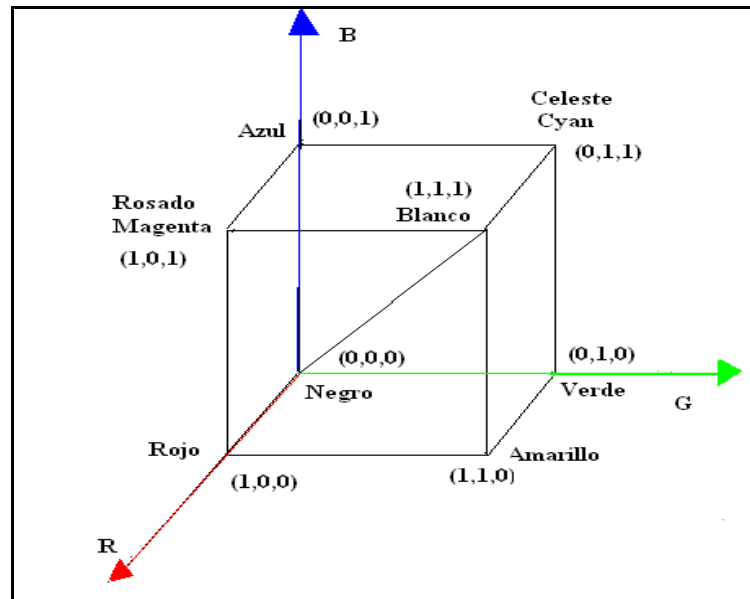


Fig. 2.2 Esquema cartesiano de la imagen RGB (Tomado de: [42])

- **Imágenes en escala de grises**

Imágenes en escala de grises donde el valor de cada píxel equivale al nivel de luminosidad utilizan distintos tonos de gris. En imágenes de 8 bits, puede tener hasta 256 tonos de gris [0 255]. Cada píxel tiene un valor de brillo comprendido entre 0 (negro) y 255 (blanco) [17].

- **Imágenes binarias**

Una imagen binaria es un arreglo lógico de 0s y 1s. Utiliza uno de los dos valores de color (blanco o negro) para representar los píxeles de una imagen. Existen además imágenes con una profundidad de píxel de 32 bits. Los 8 bits (1 byte) adicionales de profundidad sobre las imágenes de 24 bits, le permiten almacenar la transparencia de la imagen. Este byte

adicional es generalmente llamado máscara o canal alfa, y almacena diferentes valores de transparencia. [44]

2.2.10. Etapas del procesamiento digital de imágenes

El tratamiento digital de imágenes comprende hardware, software y recursos teóricos, donde debe existir un conocimiento previo sobre cómo será el resultado. Gonzales y Woods (1996) [17] indican que este conocimiento no sólo guía la operación de cada módulo de procesamiento como se observa en la Fig. 2.3 sino que también ayuda en las operaciones de realimentación entre ellos a través de la base de conocimiento. Dicho conocimiento puede simplemente detallar regiones en una imagen para ubicar información de interés; como puede ser una base de datos que contenga imágenes de alta resolución.

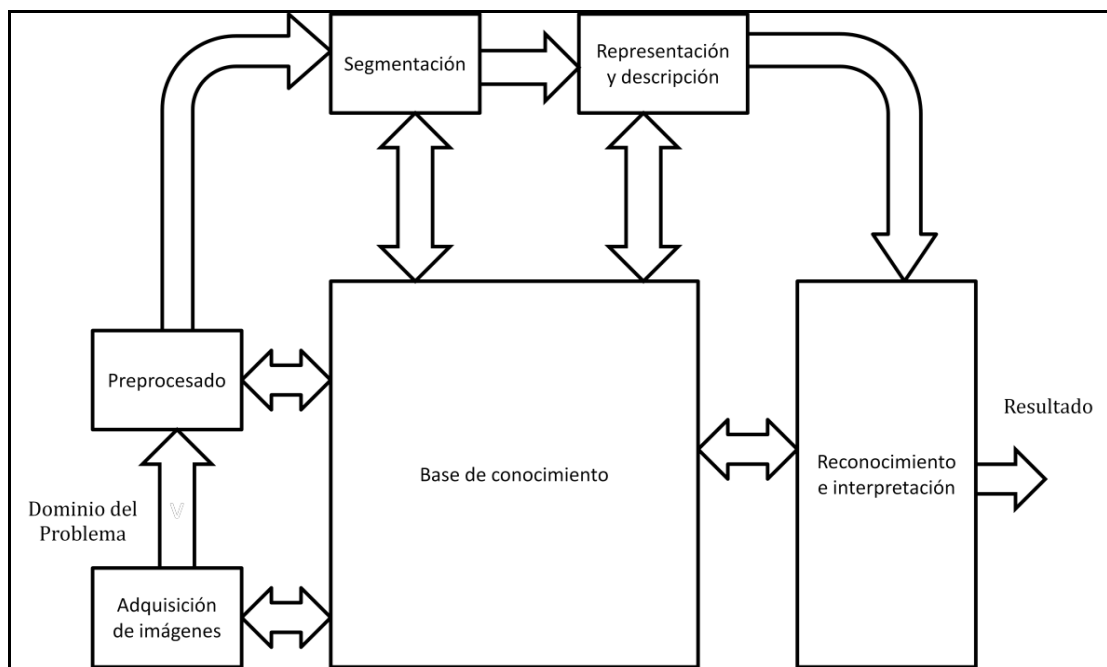


Fig. 2.3 Etapas fundamentales de un Sistema de Visión Artificial (Tomado de: [17])

2.2.10.1. Adquisición de la imagen

La primera etapa es la adquisición de la imagen. Para esta etapa se necesitan dos elementos: el primero es un dispositivo físico sensible a una determinada banda del espectro de energía

electromagnética y que produzca una señal eléctrica de salida proporcional al nivel de energía detectado; el segundo, es un medio para convertir la señal de salida del sistema a forma digital. Entre estos dispositivos para adquirir imágenes destacan las cámaras digitales, cámaras filmadoras, cámaras web, entre otros.

2.2.10.2. Pre-procesamiento de la imagen

El pre-procesamiento es la etapa en la cual se realizan procedimientos para mejorar la imagen de forma que se aumenten las posibilidades de éxito en los procesos posteriores. Consiste en aplicar técnicas de mejoramiento del contraste, eliminar el ruido y aislar regiones cuya textura indica la probabilidad de información necesaria para el estudio mediante procedimientos que normalmente se expresan en forma de algoritmos [17].

Conversión de una imagen RGB a escala de grises

La conversión de una imagen RGB a escala de grises se realiza a través del cálculo que resulta de considerar una variable equivalente E , formada entre los valores contenidos en cada plano de color que lo constituyen. En su forma más sencilla podría establecerse este equivalente como el promedio de los valores de los tres componentes como se indica en la Ecuación 2.4 [44].

$$E_p = \frac{R(x,y) + G(x,y) + B(x,y)}{3} \quad (2.4)$$

La subjetiva iluminación, propia del modelo RGB, hace que imágenes con un valor grande en la componente de rojo y/o verde tengan una apariencia oscura (en la imagen a escala de grises convertida mediante la Ecuación 2.4). El efecto contrario sucede en aquellos píxeles donde el contenido del plano azul es grande, mostrando en su versión a escala de grises una apariencia más clara. Con el objetivo de solventar este problema se considera como una mejor aproximación calcular una combinación lineal de todos los planos, definida en la Ecuación 2.5.

$$E_{lin} = w_R R(x,y) + w_G G(x,y) + w_B B(x,y) \quad (2.5)$$

Dónde: w_R, w_G y w_B son los coeficientes que definen la transformación, los cuales de acuerdo al criterio utilizado en la TV para señales a color consideran en la Ecuación 2.6.

$$w_R = 0.299, \quad w_G = 0.587 \quad w_B = 0.114 \quad (2.6)$$

Técnicas de realce de imágenes

- **Basadas en histograma**

Un histograma es una distribución de los valores de nivel de gris de todos los píxeles de la imagen. Dicho de otra forma, un histograma ilustra en un gráfico cómo están distribuidos los píxeles de la imagen mostrando la cantidad de píxeles en cada nivel de intensidad del color. El histograma indica si la imagen contiene suficientes detalles en las sombras (en la parte izquierda del histograma), en los medios tonos (en el centro) y las iluminaciones (en la parte derecha) para realizar una corrección correcta. [45]

Matemáticamente el histograma es una función discreta que contabiliza el número de ocurrencias de cada nivel de gris que presenta en una imagen. En el eje de abscisa está el nivel de gris y en el de ordenadas la frecuencia de cada nivel de gris en la imagen. Si al histograma se le divide por el número de píxeles de la imagen se obtendrá la función de probabilidad de cada nivel de gris en la imagen. [46]. El histograma de una imagen se define según la Ecuación 2.7.

$$p(r_k) = \frac{n_k}{n}; \quad k = 0, 1, 2, \dots, L \quad (2.7)$$

Dónde r_k es el k-ésimo nivel de gris o valor intensidad, n_k es el número de píxeles de la imagen con ese valor de nivel de gris, n es el número total de píxeles de la imagen y L es el máximo nivel de gris, por ejemplo $L = 1$ para una imagen binaria, $L = 255$ en una imagen de 8-bits y $L = 16535$ para una imagen de 16-bits. De la definición anterior se puede observar que $p(r_k)$ representa la probabilidad de aparición del nivel de gris r_k . La forma

del histograma $p(r_k)$, da una idea de la apariencia global de la imagen, es decir, observando la distribución del histograma se puede inferir si la imagen es oscura, brillante, de bajo o alto contraste. Sin embargo, el histograma no proporciona información sobre la distribución espacial de los píxeles en la imagen.

Histograma normalizado: Si al histograma se le divide por el número de píxeles de la imagen se obtendrá la función de probabilidad de cada nivel de gris en la imagen, lo que se denomina como histograma normalizado (Ecuación 2.8).

$$p(i) = \frac{h(i)}{M \cdot N} \quad (2.8)$$

Siendo $h(i)$ el número de ocurrencia del nivel de gris i en la imagen, M y N el número de filas y columnas de la imagen, $p(i)$ la probabilidad de que ocurra el nivel de gris i en la imagen. [45]

- **Basadas en mejora de Contraste**

El aumento de contraste consiste en incrementar el rango dinámico de los niveles de gris presentes en la imagen que está siendo procesada. Algunas causas de bajo contraste en una imagen digital son: baja iluminación del objetivo ocular, incorrecta apertura del lente al momento de la captura de la imagen, entre otras.

Igualación o ecualización del histograma: Esta técnica se basa en tratar de transformar el histograma de una imagen para obtener un histograma uniforme, es decir, que la probabilidad de cualquier nivel de gris en la imagen sea la misma. La transformación de nivel de gris para esta técnica viene dada por la Ecuación 2.9.

$$s_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} \quad (2.9)$$

Donde las variables están especificadas en la Ecuación 2.7, de manera adicional se tiene que los niveles de gris r_k están normalizados, esto es, pertenecen al intervalo $[0, 1]$, donde 0 es el negro y 1 es el blanco. La función de transformación cumple las siguientes condiciones según [47]:

1. $T(r)$ es de valor único y monótonamente creciente en el intervalo $0 \leq r \leq 1$
2. $0 \leq T(r) \leq 1$ para $0 \leq r \leq 1$

La condición 1 conserva el orden entre blanco y negro de la escala de grises, mientras la condición 2 garantiza una aplicación que es coherente con el rango de valores de pixel permitidos. [47]

Filtros digitales

Los filtros digitales constituyen uno de los principales modos de operar en el procesamiento de imágenes digitales. Los filtros que se aplican para mejorar las imágenes pueden ser espaciales (lineales y no lineales) y filtros en el dominio de la frecuencia.

Los filtros se pueden aplicar a las imágenes para realizar cualquiera de los siguientes procedimientos [48]:

- ❖ **Suavizar la imagen** para reducir las variaciones de intensidad entre píxeles vecinos.
- ❖ **Eliminar ruido** y modificar aquellos píxeles cuyo nivel de intensidad es muy diferente al de sus vecinos.
- ❖ **Realzar la imagen** y aumentar las variaciones de intensidad, allí donde se producen.
- ❖ **Detectar bordes** para detectar aquellos píxeles donde se produce un cambio brusco en la función intensidad.

A continuación se explica brevemente cada uno de los tipos de filtrados:

Filtros espaciales

El término “espacial” se utiliza para distinguir que la alteración del píxel se realiza dependiendo de los valores de los píxeles del entorno sin realizar ninguna modificación previa de sus valores.

Operar en el dominio espacial es operar directamente con los valores de intensidad de los píxeles de la imagen. Los filtros espaciales pueden ser lineales o no lineales.

Los lineales pueden expresarse con una máscara espacial y se aplican mediante una operación de convolución (*). Los filtros espaciales lineales pueden ser:

Filtro de la media o promediado

El filtro de la media es un filtro lineal de paso bajo en donde cada píxel de la imagen resultante $g(x, y)$, toma el valor de la media aritmética correspondiente a los píxeles de su entorno de vecindad "S", cuya dimensión es $m \times n$ como se indica en la Ecuación 2.10.

$$g(x, y) = \frac{1}{m * n} \sum_{(i,j) \in S} f(i, j) \quad (2.10)$$

Para un filtro espacial de 3x3 (grado 3), la construcción más simple consiste en una máscara en la que todos los coeficientes sean iguales a 1. Sin embargo, la respuesta, en este caso es, la suma de los niveles de gris de los nueve píxeles, lo que hace que el resultado quede fuera del rango válido de gris [0,255]. La solución consiste en cambiar la escala de la suma, dividiéndola por el grado de la máscara al cuadrado, en este caso por 9. La Fig. 2.4 muestra la máscara resultante [49].




Fig. 2.4 Máscara 3x3 utilizada por el filtro de la media (Tomado de: [49])

Filtro de la Mediana.- Éste se basa en sustituir el valor del píxel central por el de la mediana del conjunto formado por el mismo y sus ocho vecinos. Es una operación no lineal que se suele utilizar en el procesamiento de imágenes para reducir el ruido "sal y pimienta". El filtro de la mediana es más efectivo cuando el objetivo es reducir el ruido y al mismo tiempo preservar los bordes. [42]

Realce espacial mediante filtros *High-boost* o *Unsharp*

El uso de filtros de reducción de ruido puede afectar a la nitidez, por lo que es conveniente recuperarla acentuando los detalles de la imagen. El método más sencillo es la aplicación de un filtro paso-alto, pues éste deja pasar las componentes de alta frecuencia y éstas son las que contienen la información de detalles de la imagen. Una imagen resultante de la aplicación de un filtro de paso alto puede calcularse como la diferencia entre la imagen original y el resultado de aplicar un filtro de paso bajo a dicha imagen.

Paso alto = Original - Paso bajo

El filtro *high-boost* o de énfasis de las frecuencias altas, puede definirse de la siguiente forma como se visualiza en la Ecuación 2.11.

$$\begin{aligned}
 \textit{High-boost} &= (A)(\textit{Original}) - \textit{Paso Bajo} \\
 &= (A - 1)(\textit{Original}) + \textit{Original} - \textit{Paso bajo} \\
 &= (A - 1)(\textit{Original}) + \textit{Paso alto} \qquad (2.11)
 \end{aligned}$$

Dónde "A" es un escalar, tal que: A = 1 corresponde a un filtro de paso alto normal.

A > 1, implica que se añade al resultado del filtrado parte de la imagen original, devolviendo parcialmente las componentes de baja frecuencia eliminadas, de manera que se obtiene una imagen más cercana a la original, con un énfasis de bordes que depende de A.

2.2.10.3. Segmentación

La segmentación consiste en partir una imagen de entrada en sus partes constituyentes, siendo esta etapa una de las más difíciles pues un procedimiento de segmentación mal realizado garantiza que tarde o temprano habrá un fallo. La segmentación busca destacar el objeto en estudio ROI sobre el fondo de la imagen, desechando la información sin utilidad, para posteriormente aplicar las herramientas necesarias para el análisis del objeto destacado. La segmentación debería aislar el mayor número posible de anomalías, aunque entre las ROIs se encuentren regiones correspondientes a tejido sano (falsos positivos). [17] Existen diversas técnicas de segmentación, algunas de ellas son:

- **Segmentación por detección de regiones**

La segmentación por detección de regiones consiste en dividir la imagen en regiones homogéneas teniendo en cuenta una o más características (como brillo o color), esto se hace para facilitar procesos posteriores como el reconocimiento y la interpretación de objetos. En este proceso, partiendo de la imagen, se produce otra cuyos píxeles están etiquetados dependiendo del objeto al que pertenecen. Con esto, una vez segmentada la imagen, se formará una lista de objetos juntando a todos los píxeles que tengan la misma etiqueta.

- **Umbralización Simple**

Se usa en imágenes que tienen buen contraste entre los diferentes objetos que se desean aislar, por lo que se puede establecer un valor fijo en el histograma de la imagen que marque el umbral de separación. El histograma de la imagen tiene información sobre los niveles de intensidad de los objetos a segmentar y del fondo de la imagen. Con esto, partiendo de la imagen original $f(x, y)$ se obtiene la imagen binaria $BW(x, y)$ en función de un valor U correspondiente al umbral de separación seleccionado, mediante la Ecuación 2.12.

$$BW(x, y) = \begin{cases} 1 & \text{si } f(x, y) \geq U \\ 0 & \text{si } f(x, y) < U \end{cases} \quad (2.12)$$

La elección del umbral es el paso más importante para desarrollar la segmentación de la imagen de forma satisfactoria.

- **Binarización**

La binarización es obtener una imagen que sólo sea representada por dos tonos de color, generalmente, blanco y negro. Para ello sólo debemos decidir cuál de los dos tonos de color dar a cada píxel de la imagen de entrada. Esta tarea se lleva a cabo especificando un valor umbral o límite también llamado umbral de binarización.

Con esta técnica, los valores de píxel en la imagen de entrada menores a un cierto umbral (entre 0 y 255) son convertidos a negro mientras que los píxeles con valores mayores o iguales al umbral son convertidos a blanco.

El valor de la intensidad mayor o igual a un umbral se les asigna el máximo valor de gris (255=blanco). Por su parte, los píxeles comprendidos por debajo de este valor toman el valor mínimo (0=negro).

Operaciones morfológicas

La Morfología matemática es una técnica de procesado no lineal de la imagen, interesada en la geometría de los objetos. Las operaciones morfológicas proporcionan información sobre la forma o estructura de una imagen. El análisis morfológico permite extraer componentes de la imagen que son útiles en la representación y descripción de la forma de las regiones como: fronteras, esqueletos y permite obtener características relevantes de los objetos en la imagen como: forma, tamaño. [42]

Operadores morfológicos son los más adecuados para la extracción selectiva o supresión de estructuras de la imagen. La selección se basa en su forma, tamaño y orientación. Mediante

la combinación de los operadores elementales, se pueden lograr importantes tareas de procesamiento de imágenes. [45]

Elemento estructurante

Define la forma y el tamaño de la vecindad del píxel que será analizado, para posteriormente alterar su valor. Formada por ceros y unos de forma y tamaño arbitrario en la cual las posiciones donde está el uno define la vecindad. La Matriz que define el elemento estructural tiene un tamaño muy inferior al tamaño de la imagen a la que modificará. El elemento estructural define el tamaño y la forma de la vecindad en la que se aplicará la operación morfológica. Dentro de las formas del elemento estructural tenemos: cuadrado, diamante, disco, línea, círculo, rectángulo, octágono [44]. El tamaño y la forma se escogen de acuerdo a las formas que se deseen extraer.

Las operaciones morfológicas básicas son:

- **Dilatación**

La dilatación es una operación morfológica que crece o aumenta el grosor de objetos en una imagen binaria. La manera específica y el grado de este engrosamiento está controlado por la forma que tenga el elemento estructurante (SE) [45]. La dilatación expande los píxeles de la imagen sobre la que se aplica. La dilatación de A por B, denotada por $A \oplus B$, está definida por la Ecuación 2.13. En concreto, la dilatación es el conjunto de puntos de todas las posibles sumas de pares de elementos de cada conjunto A y B.

$$A \oplus B = \bigcup_{\beta \in B} (A + \beta) \quad (2.13)$$

En la Fig. 2.5 se observa la imagen original (a), el elemento estructurante (b), con 3 píxeles alineados en un ángulo de 135°. El origen del SE está claramente identificado con rojo, La imagen dilatada (c), que se expandió 1 en cada posición del origen de tal manera que se

superpone al elemento de la estructura en el valor de 1 píxel de la imagen de entrada (a). [45]

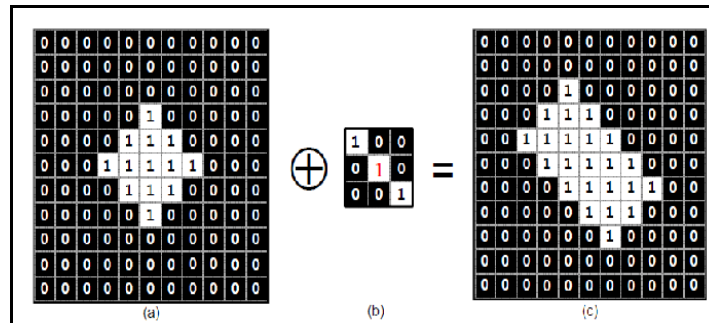


Fig. 2.5 Dilatación Morfológica. (Tomado de: [46])

La dilatación sirve para: ampliar bordes, unir objetos próximos y eliminar detalles negros pequeños

- **Erosión**

La erosión reduce o adelgaza, los objetos en una imagen, además sirve para reducir bordes, separar objetos próximos, eliminar puntos blancos separados, ampliar detalles negros pequeños. Es la operación cuasi-inversa de la dilatación. Está definida por la Ecuación 2.14.

$$A \ominus B = \bigcup_{B \in \mathcal{B}} (A - B) \quad (2.14)$$

- **Apertura**

Una vez que una imagen se ha erosionado, existe en general una transformación inversa para obtener la imagen original de nuevo. La idea detrás de la apertura morfológica es para dilatar la imagen erosionada para recuperar tanto como sea posible la imagen original. La apertura remueve completamente regiones de un objeto que no han sido contenidos en el SE, generalmente suaviza los límites de los objetos más grandes sin cambios significativos en su área rompe objetos en los puntos finos, además elimina las protuberancias pequeñas y delgadas.

Segmentación Automática de la Región de Interés

La segmentación de la región de interés de la imagen se ha realizado mediante la técnica de extracción de la ROI desarrollado por Rafael De Souza Marques [50], el cual consiste en una herramienta llamada segmentador, implementada en lenguaje C++, que requiere pasar como parámetros la imagen original previamente preprocesada y convertida a niveles de gris con 120 tonos de gris, para la mínima temperatura encontrada se asigna un valor 0 (negro) y para la máxima el valor 255 (blanco), las demás temperaturas encontradas son reescaladas en el intervalo de 0 a 255. También se puede introducir la matriz de temperaturas de la imagen, en vez de la imagen original. Para entender este proceso los pasos del método propuesto por Márquez [50], se detallan a continuación.

El segmentador identifica la región de interés que cubre la mama derecha y la mama izquierda de cada imagen, este procedimiento de la extracción del ROI se visualiza en la Fig. 2.6, la cual consta de tres pasos: Detección de los contornos laterales, obtención de los límites superiores y obtención de los límites inferiores.




Fig. 2.6 Etapas de segmentación automática: detección de límites laterales, superiores e inferiores (Tomado de: [50])

Para la detección de límites laterales se realiza dos etapas, primero se elimina el fondo de la imagen mediante la utilización del método de Otsu [51], después se obtiene el contorno del cuerpo mediante un detector de bordes, para este caso se utilizó el Filtro Laplaciano como se indica en la Fig. 2.7.




Fig. 2.7 Aplicación del método Otsu y del Filtro Laplaciano (Tomado de: [51])

Para detectar los límites superiores se identifica la presencia o ausencia de brazos en la imagen, se calcula los puntos donde se producen las alternancias, el procedimiento implementado se visualiza en la Fig. 2.8




Fig. 2.8 Procedimiento para detectar límites superiores

a) Puntos de alternancias encontrados, **b)** Crecimiento de regiones en los dos puntos encontrados, **c)** Segmentación de los puntos. (Tomado de: [50])

En la Fig. 2.9 se observa el procedimiento para la separación de mamas derecha e izquierda respectivamente.

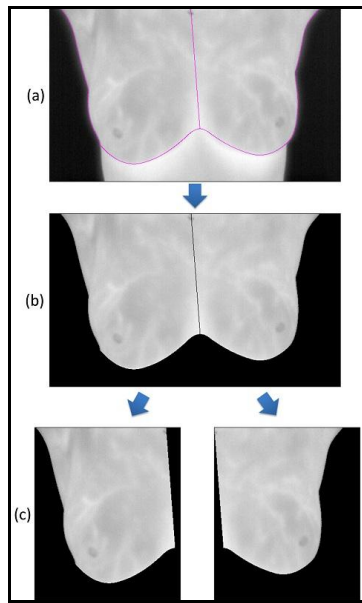


Fig. 2.9 Resultado de separación de las mamas para la imagen IR_0225 (Tomado de: [50])

2.2.10.4. Representación y Descripción

En la salida del proceso de segmentación se tienen los datos de pixel en bruto, que constituyen el contorno de una región o bien todos los puntos de una región determinada. En cada caso es necesario convertir los datos a una forma adecuada para su procesamiento y decidir si los pixeles constituyen un contorno o una región completa: la representación como un contorno es la adecuada cuando el interés radica en las características de la forma exterior (esquinas), mientras que la representación regional es adecuada cuando el interés se centra en propiedades internas (como textura o estructuración). La descripción consiste en extraer los rasgos con alguna información cuantitativa de interés para poder diferenciar una clase de objetos de otra. [17]

2.2.10.5. Extracción de características

Una vez segmentada la imagen, puede ser necesario extraer características de las distintas ROIs seleccionadas para determinar con mayor precisión el nivel de sospecha. El espacio de características puede ser muy grande y complejo, debido a la gran variabilidad que puede darse tanto en el tejido sano como en el canceroso. Sin embargo, no todas las

características obtenidas son igualmente significativas. Usar un número excesivo de características puede incrementar la complejidad del clasificador y degradar el rendimiento del mismo.

Para reconocer un objeto de la imagen es necesario extraer características que permitan representarlo y describirlo matemáticamente [52]. Descripción matemática del/os objeto/s:

- Color
- Tamaño
- Posición

Por lo tanto se crea un vector de características que contempla los siguientes descriptores [52]:

- Descripción del Contorno
 - Códigos de cadena
 - Aproximación polinomial
 - Representación polar
 - Esqueletización
 - Descriptores de Fourier
- Descripción de Región
 - Momentos
 - Descriptores topológicos
 - Textura
- Descripción de Similitud:
 - Correlación

Textura

La textura [53] es una característica importante utilizada en la identificación de objetos o regiones de interés en una imagen. El uso de la textura para identificar una imagen proviene de la habilidad innata de los humanos para reconocer diferencias texturales. Por consiguiente, la textura es una característica de difícil definición, siendo la más extendida la

dada por Haralick [54]: “Una textura está definida por la uniformidad, densidad, grosor, regularidad, intensidad y direccionalidad de medidas discretas del tono en los píxeles y de sus relaciones espaciales”. En general la textura [55] es una propiedad asociada con las superficies tales como suavizado, rugosidad, granularidad, regularidad, etc. En sistemas de reconocimiento de imágenes la textura se considera como la repetición espacial de patrones en una superficie.

Descripción de texturas, enfoque estadístico

Habiendo seleccionado ya el esquema de representación interno, en el cual el interés está en los píxeles que forman la imagen. Pueden ser obtenidas características de tipo estadístico a partir de la imagen, recordando que esta se puede entender como un conjunto discreto de datos, donde cada uno representa la intensidad de un cierto pixel.

El n-ésimo momento alrededor de la media de un conjunto discreto de datos según [56] está dado por la Ecuación 2.15 mediante momentos del histograma:

$$\mu_n = \sum_{i=0}^L (z_i - m)^n p(z_i) \quad (2.15)$$

Donde z_i representa una variable aleatoria discreta, $p(z)$ es el histograma de la imagen, L es el máximo nivel de gris que puede tomar la imagen (depende sí esta es de 8-bits, 16-bits, etc.) y m es la media o intensidad promedio de la imagen. Se presentan a continuación un conjunto de descriptores útiles en la representación estadística de características de las imágenes digitales [47, 57].

La fórmula para el cálculo de la **Intensidad promedio** se indica en la Ecuación 2.16.

$$m = \sum_{i=0}^L z_i p(z_i) \quad (2.16)$$

Para el cálculo del **contraste promedio** se visualiza en la Ecuación 2.17 y la **medida de la suavidad relativa** en la Ecuación 2.18.

$$\sigma = \sqrt{\mu_2(z)} \quad (2.17)$$

$$R = 1 - \frac{1}{1 + \sigma^2} \quad (2.18)$$

La **medida de la asimetría del histograma** se calcula mediante la Ecuación 2.19, la **uniformidad de niveles de gris** según la Ecuación 2.20 y la **entropía** por la Ecuación 2.21

$$\mu_3 = \sum_{i=0}^L (z_i - m)^3 p(z_i) \quad (2.19)$$

$$U = \sum_{i=0}^L p(z_i)^2 \quad (2.20)$$

$$e = - \sum_{i=0}^L p(z_i) \log_2 p(z_i) \quad (2.21)$$

Sin embargo, existe otra forma de extraer características estadísticas de la imagen, teniendo en cuenta ahora no solamente la distribución de niveles de gris, sino también la posición relativa de píxeles que tienen iguales, o casi iguales niveles de intensidad. Esta forma de describir la textura posibilita la identificación de patrones en la textura.

2.2.10.6. Clasificación

El aprendizaje computacional consiste en crear sistemas capaces de optimizar un criterio de rendimiento usando datos de ejemplo o experiencias pasadas. Una cualidad para considerar a un sistema inteligente es la posibilidad de adaptar su comportamiento futuro respecto a experiencias obtenidas del pasado. El aprendizaje implica cambios de adaptación en el sistema, que permiten llevar a cabo las mismas tareas a partir de las mismas condiciones de un modo cada vez más eficiente. De forma general se puede decir que el aprendizaje computacional se realiza mediante dos fenómenos:

- **La perfección de una habilidad** consiste en que el sistema produce respuestas más óptimas conforme se va ejecutando a través del tiempo.
- **La adquisición de conocimiento** el sistema recoge y cataloga de forma supervisada o automática información externa para utilizarla en posteriores consultas.

La forma en la que el sistema de aprendizaje adquiere el conocimiento y la forma en la que proporciona su salida da lugar a los diferentes tipos de aprendizaje.

- ❖ **Aprendizaje supervisado.** Genera una función que establece una correspondencia entre las entradas y las salidas deseadas del sistema. Un ejemplo de este tipo es el problema de “clasificación”, donde el sistema de aprendizaje trata de etiquetar (clasificar) una serie de vectores utilizando una entre varias categorías (clases). La base de conocimiento del sistema está formada por ejemplos etiquetados anteriormente.
- ❖ **Aprendizaje no supervisado.** Todo el proceso de modelado se lleva a cabo sobre un conjunto de ejemplos formado tan sólo por entradas al sistema. No se tiene información previa sobre las etiquetas de esos ejemplos. Ejemplos de este tipo de algoritmos son el agrupamiento y la compresión de datos [58].

Clasificador K-NN (*K-Nearest Neighbor*)

K-NN es un método de clasificación supervisada. La idea básica sobre la que se fundamenta esta técnica es el uso de reglas basadas en la vecindad. Las reglas de clasificación por vecindad buscan encontrar un conjunto de patrones de los k patrones (vecinos) más cercanos al patrón a clasificar.

La regla de clasificación por vecindad más simple es la regla de clasificación del vecino más cercano (próximo) 1-NN

Para ello, se debe especificar una métrica para poder medir la proximidad. Suele utilizarse por razones computacionales la distancia Euclídea, δ para este fin.

Distancia Euclídea

La distancia Euclídea [59] es una de las métricas más utilizadas, ésta se obtiene a partir de una generalización del teorema de Pitágoras. En un espacio tridimensional, la distancia euclídea entre 2 puntos (X_1, X_2, X_3) y (Y_1, Y_2, Y_3) viene dada por la siguiente Ecuación 2.22

$$d = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + (x_3 - y_3)^2} \quad (2.22)$$

Más concretamente, la distancia euclidiana entre dos puntos p1 y p2 se indica en la Ecuación 2.23.

$$d(p1, p2) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (2.23)$$

Algoritmo K-NN básico

Su principio de operación es muy sencillo: dado un conjunto de muestras de entrenamiento t_{ij} pertenecientes a una de las J clases diferentes C_1, \dots, C_J , un nuevo caso desconocido x se asignará a la clase C_m que tenga la muestra del conjunto de entrenamiento más cercana a este caso x. En general en los métodos K-NN se consideran los k vecinos más cercanos de x dentro del conjunto de entrenamiento y se considera C_m como la clase que tiene más muestras entre los k vecinos considerados

Para un nuevo caso que se pretenda clasificar, denotado como $X = (x_1, \dots, x_n)$, se realiza el siguiente algoritmo.

1. Se calculan las distancias (d_i) de todos los casos ya clasificados al nuevo caso X.

$$D_x = (d_1, d_2, \dots, d_N) \text{ donde } d_i = d(X_i, X)$$

La distancia que se utiliza típicamente es la distancia Euclídea, pues nos encontramos en un espacio n-dimensional, y se calcula como se indica en la Ecuación 2.24.

$$d(X_i, X) = \sqrt{(X_{i,1} - X_1)^2 + (X_{i,2} - X_2)^2 + \dots + (X_{i,n} - X_n)^2}$$

$$= \sqrt{\sum_{j=1}^n (X_{i,j} - X_j)^2} \quad (2.24)$$

2. Se obtienen las K menores distancias D_x^K y los K casos conocidos que las generan X^K
3. Finalmente se clasifica el nuevo caso X a la clase más frecuente de los X^K

En la Fig. 2.10 se muestra un ejemplo de clasificador K-NN con 25 casos ya clasificados en dos posibles valores ($m=2$ clases), en un espacio bidimensional (con dos variables x_1 y x_2 , $n=2$) y con $K=3$.




Fig. 2.10 Ejemplo de aplicación del algoritmo K-NN básico con $K=3$ (Tomado de: [58])

Se observa que de los 3 casos ya clasificados más cercanos al nuevo caso a clasificar X, (representado por ●), dos de ellos pertenecen a la clase ○ y el otro pertenece a la clase ♦. Así el clasificador 3-NN predice la clase ○ para el nuevo caso.

Cabe destacar que la fase de entrenamiento consiste en almacenar los vectores característicos y las etiquetas de los casos de entrenamiento, mientras que es en la fase de evaluación o clasificación en la que se implementa el algoritmo anterior al conjunto de casos de test.

En caso de que se produzca un empate entre dos o más clases, conviene definir una regla para su ruptura. En los casos en los que las clases solo pueden tener dos valores se suele

poner un valor de K impar para que no se produzca el empate. Para clases con más valores algunos ejemplos de reglas pueden ser: seleccionar la clase a la que pertenezca el vecino más próximo, seleccionar la clase con distancia menor, añadir nuevos vecinos más cercanos hasta que desaparezca el empate, etc.

Regla 1-NN

La regla de clasificación por vecindad más simple es la regla de clasificación del vecino más cercano o simplemente 1NN.

Se basa en la suposición de que la clase del patrón a etiquetar, X, es la del prototipo más cercano en R, (conjunto de referencia) al que notaremos por X_{NN} . Esta regla puede expresarse como se indica en la Ecuación 2.25

$$d(X) = w_c \text{ si } \delta(X, X_{NN}) = \min_i = 1 - \frac{1}{N} \delta(X, X_i) \quad (2.25)$$

En la Fig. 2.11, se visualiza un ejemplo de cómo se clasificaría el patrón X con la regla 1NN para un problema de clasificación de dos clases. Existen cuatro prototipos de clase 1 (representados por cruces) y cinco prototipos de clase 2 (representados por asteriscos). El prototipo más cercano es de clase 2, por lo que ésta será la clase asociada a X. [60]

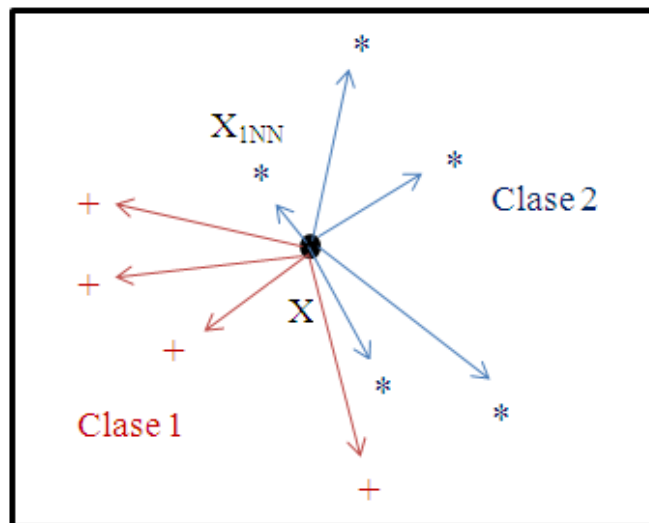


Fig. 2.11 Ejemplo de clasificación 1NN (Tomado de: [60])

2.2.10.7. Métricas de evaluación

Para evaluar el desempeño del algoritmo de clasificación se ha utilizado principalmente las siguientes métricas: La precisión, especificidad y sensibilidad, la matriz de confusión.

Matriz de Confusión

La matriz de confusión es una herramienta de visualización empleada en los sistemas de aprendizaje supervisado que contiene información acerca de la clasificación real y predicha dada por el clasificador. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa las instancias reales de cada clase. Los beneficios de las matrices de confusión es que muestra gráficamente la calidad del clasificador y facilita ver si el sistema está confundiendo dos clases.

La Tabla 2.1 muestra la matriz de confusión para un clasificador de dos clases, donde las entradas de la misma tienen los siguientes significados:

- **TN** (True Negative, Verdaderos Negativos) es el número de correctas predicciones que en realidad son negativas.
- **FP** (False Positive, Falsos Positivos) es el número de incorrectas predicciones que en realidad son negativas.
- **FN** (False Negative, Falsos Negativos) es el número de incorrectas predicciones que en realidad son positivas.
- **TP** (True Positive, Verdaderos Positivos) es el número de correctas predicciones que en realidad son positivas.

Tabla 2.1 Matriz de confusión para un clasificador de dos clases

| | | Real | |
|----------|----------|----------|----------|
| | | Positivo | Negativo |
| Predicho | Positivo | TP | FP |
| | Negativo | FN | TN |

Tomado de: [61]

Precisión, Cobertura y Medida-F

Así, la matriz de confusión permite hacerse una idea de la eficiencia del algoritmo pero no aporta detalles relativos a cómo de bien, o mal, se está llevando a cabo la clasificación. Por este motivo se miden los siguientes tres parámetros que se definen como:

Precisión: Mide que cantidad de información de la que devuelve el sistema es correcta, expresada como el porcentaje de casos correctamente clasificados en una clase respecto al total de casos que son clasificados en esa misma clase. Es decir, es la proporción de casos predichos como correctos por el clasificador (Ecuación 2.26).

$$\text{Precisión}(\%) = \frac{TP}{TP + FP} * 100 \quad (2.26)$$

Cobertura o Recall (Sensibilidad): Indica cuánta información relevante ha extraído el sistema, expresada como el porcentaje de casos correctamente clasificados respecto al total de casos que pertenecen a esa clase. Es decir, es la cantidad de casos clasificados correctamente como pertenecientes a una clase (Ecuación 2.27).

$$\text{Cobertura}(\%) = \frac{TP}{TP + FN} * 100 \quad (2.27)$$

Medida-F: Entre la precisión y la cobertura existe un equilibrio, de tal forma que una precisión alta disminuye la cobertura y de forma inversa una cobertura alta disminuye en cierta forma la precisión. Por esto se obtiene esta medida que es una media armónica entre la precisión y la cobertura, (Ecuación 2.28).

$$\text{Medida - F}(\%) = \frac{2 * \text{Precisión} * \text{Cobertura}}{\text{Precisión} + \text{Cobertura}} \quad (2.28)$$

TPR, Tasa de Verdaderos Positivos. Mide hasta qué punto es capaz el clasificador de clasificar los casos positivos correctamente de entre todos los casos positivos, (Ecuación 2.29).

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2.29)$$

FPR, Tasa de Falsos Negativos. Define cuántos resultados positivos son incorrectos de entre todos los casos negativos disponibles durante la prueba (Ecuación 2.30).

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (2.30)$$

La especificidad es la probabilidad de clasificar correctamente a un individuo cuyo estado real sea el definido como negativo. (Ecuación 2.31).

$$\text{Especificidad} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (2.31)$$

2.3 Propuesta de Solución

Con este trabajo se pretende desarrollar algoritmos de descripción de texturas simples para caracterizar automáticamente las lesiones de cáncer de mama mediante el uso de imágenes térmicas, beneficiando al paciente con una detección precoz de la enfermedad y a un bajo costo y los beneficios de un procedimiento no invasivo.

CAPÍTULO III

METODOLOGÍA

3.1. Modalidad de la investigación

La presente investigación se basará en una metodología de investigación aplicada. Consiste en analizar las imágenes proporcionadas por el especialista médico, para conseguir detectar en ellas de forma automática diferentes tipos de síntomas representativos de patologías. Para ello, una vez diseñados los correspondientes algoritmos, éstos se implementarán en el lenguaje MATLAB. Después, se evaluarán sus resultados usando un conjunto de imágenes de test y se intentará contar con un gold estándar.

3.2. Población y Muestra

El contexto en que se desarrollará el presente trabajo es la zona de Tungurahua, pero se investigará sobre la base de la información proporcionada por las imágenes térmicas adquiridas a las pacientes del hospital SOLCA de la ciudad de Ambato, que potencialmente requieren un estudio de una patología de mama, para tal efecto se considera como muestra inicial un conjunto de 100 imágenes de las pacientes de la Unidad Oncológica de dicho hospital con y sin patología. Se contará también con los conocimientos y el diagnóstico proporcionado por los especialistas médicos de dicho centro y que además forman parte del equipo de investigación del proyecto.

3.3. Recolección de Información

Tal como se comentó en el apartado anterior, para el presente trabajo se espera experimentar con una muestra de alrededor de 100 imágenes adquiridas de las pacientes del Hospital de SOLCA, las obtenidas de la base de datos [62]. Además de las imágenes

obtenidas base de datos proporcionadas por los miembros del equipo investigador de la Universidad de Brasil [63]. Todas las imágenes tienen asociadas su correspondiente diagnóstico médico. Para ambos conjuntos de imágenes, se dispone de muestra correspondiente a mujeres sanas y con diferentes grados de patologías.

3.4. Procesamiento y análisis de los datos

En el proyecto se desarrollarán diversos algoritmos de tratamiento de imágenes para el problema planteado (p.ej. algoritmos de filtrado, segmentación y descriptores de texturas simple). Una vez procesadas las imágenes con dichos algoritmos, se compararán los resultados automáticos con el conocimiento de los expertos médicos.

3.5. Desarrollo del proyecto

- Análisis de las imágenes de las bases de datos [62], [63] y las proporcionadas por SOLCA.
- Pre-procesamiento de la imagen con el objetivo de resaltar los componentes de la imagen de interés y reducir o eliminar las que no son de interés.
- Extracción de características para adquirir información cuantitativa de los elementos constitutivos de interés de la imagen con el fin de diferenciar entre clases. Los elementos de interés como son: externos (de contorno) e internos (los píxeles que comprenden una región)
- Definición de los algoritmos para la obtención de los descriptores.
- Segmentación de la imagen para aislar los objetos constituyentes de la imagen que son de interés para el análisis
- Extracción de los descriptores de textura simple en la región de interés (ROI) obtenido durante la segmentación.
- Validación de los resultados con los diagnósticos proporcionados por el especialista médico que participa en el proyecto de investigación.

CAPÍTULO IV

DESARROLLO DE LA PROPUESTA

En este capítulo se presenta el desarrollo de la metodología propuesta para la detección de alteraciones en las mamas mediante los termogramas. Se detallan los procedimientos para la adquisición de las imágenes térmicas, y las etapas del procesamiento digital de imágenes propuesto en Gonzales y Woods (1996) [17]. Para ello, se ha tenido en cuenta las etapas de pre-procesamiento, segmentación, extracción de características de textura, la clasificación y evaluación del rendimiento de los mismos, así como otros pasos necesarios para dar solución al problema planteado.

A continuación se detalla el proceso realizado para el desarrollo de la propuesta acorde a los objetivos planteados.

4.1. Análisis de las imágenes de la base de datos utilizadas

Una imagen termográfica es aquella que muestra la distribución de la temperatura en las superficies de los objetos mediante diferentes colores para los diferentes valores de temperatura. [30]

Para realizar el análisis de las imágenes termográficas se utilizó una computadora personal y herramientas de procesamiento de imágenes tales como el Image processing Toolbox de Matlab2014a [39] y el FLIR Software v9.0. Para efectuar cada una de las tareas propuestas en esta TEMI se ha desarrollado una interfaz gráfica de usuario mediante la herramienta GUIDE proporcionada por Matlab R2014a [39], y el segmentador [50]

Los requerimientos del equipo y las herramientas utilizados se especifican en la Tabla 4.1.

Tabla 4.1 Requerimientos del software Matlab R2014a

| 32 Bit y 64 Bit Familia de productos Matlab | |
|--|--|
| Sistema Operativo | Windows 8 |
| Procesador | Any Intel or AMD x86 processor supporting SSE2 instruction set |
| Espacio en el disco | 1 GB for MATLAB only, 3–4 GB for a typical installation |
| RAM | 1024 MB (At least 2048 MB recommended). |
| Costo | \$ 1.300 |

Tomado de: [39]

4.2. Método propuesto para el procesamiento digital de las imágenes termográficas

El método que se propone desarrollar en este TEMI para realizar el procesamiento de las imágenes térmicas de mama, se muestra en el diagrama de bloques de la Fig. 4.1.

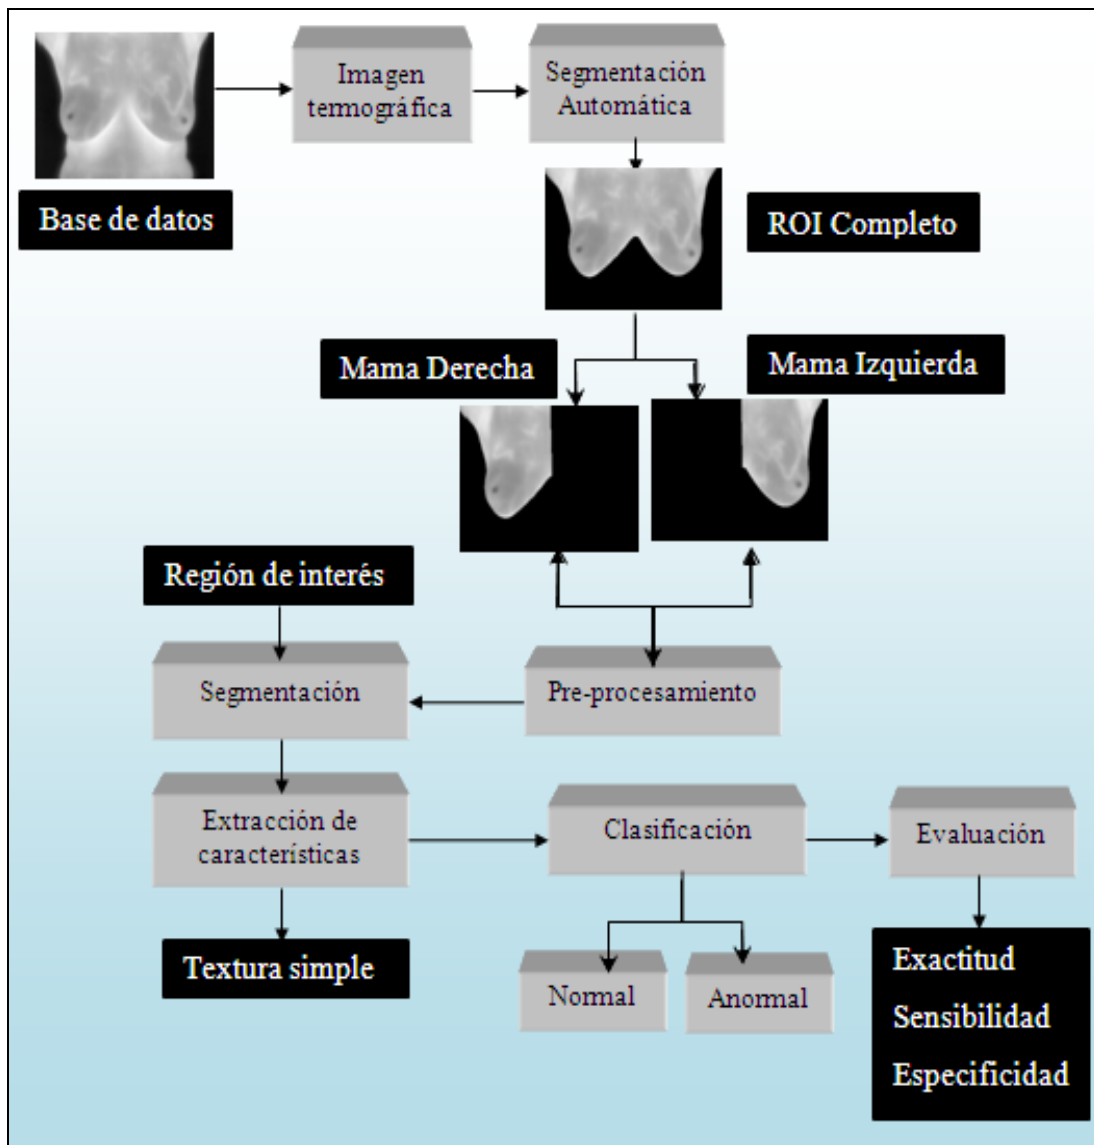


Fig. 4.1 Diagrama de bloques del método propuesto para el procesamiento digital de las imágenes termográficas. (Diseñado por la investigadora)

A continuación se describe cada una de las etapas del diagrama de bloques mostrado en la Fig. 4.1

4.2.1 Adquisición de las Imágenes Termográficas

Se procedió a la utilización de las imágenes termográficas de la base de datos [62], además de la base de datos UFF [63] y las proporcionadas por el Hospital SOLCA las cuales fueron

capturadas mediante una Cámara Térmica FLIR, modelo T420 (320×240 píxeles), intervalo de temperaturas: -20°C a +650°C, zoom digital 4x, 4 marcador de imagen, Delta T. Además de posibilitar los Informes instantáneos mediante el software FLIR Versión 9.0, instalada en dicha institución.

Los protocolos de adquisición configurados para esta cámara fueron: Emisividad de 0.97 a 0.98, una temperatura ambiente atmósfera de 17°C y una temperatura reflejada de 17°C, humedad relativa del 50% y la paleta de colores Arco Iris. Debido al reducido espacio de la sala de adquisición de dicha institución la distancia que se estableció para ubicar al paciente fue de aproximadamente un metro.

El día de la adquisición, primero se estabiliza al paciente durante 10 minutos de reposo. A continuación la paciente se descubre en su totalidad de la cintura hacia arriba. Con los parámetros de la cámara descritos anteriormente, se debe observar en la imagen en su totalidad las dos mamas, se selecciona la paleta de colores en Rain (paleta de colores RGB para una mejor visualización de la imagen térmica). Para la captura de la imagen se debe estar a una distancia aproximada de un metro [64], la paciente debe tener los brazos detrás de la nuca separados para tener una mejor apreciación y evitar que la fotografía se deforme, las cuales no permiten visualizar la existencia de un problema en las mamas. En la Fig. 4.2 se visualiza una imagen termográfica adquirida con una cámara FLIR clasificada como TH4: Anormal



Fig. 4.2 Imagen Termográfica TH4: Anormal (Tomado de: [62])

La imagen de entrada utilizada en el diagrama de bloques del procesamiento de imágenes termográficas se ha convertido a la paleta de color gray mediante el software de la cámara

FLIR. Las imágenes se leen de una carpeta, ubicadas en el siguiente path: *C:\Documents and Settings\usuario\Mis documentos\Matlab*.

Para facilitar esta tarea y todas las que se describe a continuación se ha construido una interfaz gráfica de usuario mediante la herramienta GUIDE. GUIDE es una herramienta para la construcción de interfaces gráficas de usuario disponible en MATLAB. Dicha herramienta cuenta con las características básicas de otros programas visuales tales como Visual Basic o Visual C++. Dicha herramienta dispone de controles tales como menús, barras de herramientas, botones y controles deslizantes entre otras. Para crear la presente aplicación se han utilizado los componentes que se indican en la Tabla 4.2.

Tabla 4.2 Descripción de los componentes utilizados en la construcción de la GUI

| Control | Valor de estilo | Descripción |
|-------------|-----------------|--|
| Pop-up Menu | 'popupmenu' | Provee una lista de opciones |
| List Box | 'listbox' | Muestra una lista deslizable |
| Push Button | 'pushbutton' | Invoca un evento inmediatamente |
| Static Text | 'text' | Muestra un string de texto en una caja |
| Panel | 'uipanel' | Visualiza grupo de controles |
| Table | 'uitable' | Crear una tabla 2D |
| Axes | | Para graficar |

(Elaborado por la investigadora)

Para la lectura de las imágenes termográficas ubicadas en el *path* especificado anteriormente se desarrolló un menú, que utiliza la función *uigetfile*, que nos permite abrir dichos archivos (obtener su nombre y dirección), se especifican los argumentos que se va a utilizar en este caso el nombre, la extensión de las imágenes y la dirección; se utiliza una comparación si se desea cancelar al momento de abrir; con esta información podemos abrir cualquier archivo o ejecutar un programa, por ejemplo cargar una imagen en un *axes*, abrir un documento Excel ,etc.

Procedimiento para crear un menú y abrir la imagen termográfica

Primero se debe crear una interfaz gráfica y guardarla, en la barra de herramientas escoger la opción menú editor, escribir el nombre que se visualizará como título en la interfaz gráfica creada, incluyendo un *tag* el cual se visualizará en el *M-file editor*, además se debe dar un clic en la opción *view*.

4.2.2 Segmentación Automática

Los termogramas utilizados para el desarrollo de esta tesis se adquirieron de las bases de públicos UFPE y la UFF disponibles respectivamente en [65] y [63]. Para experimentar los algoritmos propuestos se utilizaron imágenes de 45 pacientes de la base de datos de UFF, 12 con diagnóstico saludable y 33 con diagnóstico patológico o alguna alteración en las mamas, tal como se especifica en el Anexo A.1. Para extraer las ROIs de estas imágenes se utilizó el segmentador desarrollado por Rafael De Souza Marques [50]. Las imágenes de las regiones de interés generadas por esta herramienta son: La ROI completa y la ROI de las mamas derechas e izquierda (ver anexo A.2)

4.2.3 Pre-procesamiento de la imagen termográfica

En esta etapa se mejoran las imágenes para resaltar las características principales, facilitar y mejorar la etapa del paso de la segmentación de las imágenes, para ello se realizó un realce y también se aplica algún tipo de filtrado espacial y otros procedimientos en caso de ser necesario.

- **Realce**

El procedimiento de realce permite realizar el ajuste de contraste de la imagen con valores de los límites permisibles para la imagen en RGB, la imagen se asigna a una variable, esta se expresa como una matriz; se asegura que la matriz sea de dos dimensiones para poder procesarla (es decir de RGB se pasa a gray), además de otro ajuste de contraste a la imagen. Se crea un elemento estructurante de tipo disco con radio 11, y se calcula el valor de una constante, para aplicar un filtro Top-Hat [matlab 2014a] [María G. Pérez, tesis Doctoral] que consiste en restar píxel a píxel la imagen original del resultado de aplicar sobre la misma, se elimina el ruido presente en la imagen, el resultado del pre-procesamiento aplicado sobre la imagen IR_4978 se muestra en la Fig. 4.3. En donde en la Fig. 4.3 b) se puede visualizar un aumento de contraste y las características de textura son más nítidas.




Fig. 4.3 Pre-procesamiento de la imagen de entrada.
a) Imagen Original IR_4978, b) Realce Imagen Original

A continuación se especifica el código utilizado para el pre-procesamiento que se aplicó a la imagen de la Fig. 4.3 (b):

```
%Código para realizar el realce de la imagen
imagen=imread('IR_4978.png');           %Leer la imagen IR-4978
RGB = imadjust (imagen, [], []);       %Ajuste de contraste imagen RGB
I=RGB (:,:,1);                          %Imagen de dos dimensiones
K = imadjust (I, [], []); %Ajuste de contraste imagen Gray
se = strel('disk',11);                 %Crear elemento estructurante
constante=128/(max(max(K))-min(min(K))); %Constante para el Filtro
Top-Hat
J = imsubtract(imadd(K,imtophat(K,se)), imbothat(K,se))*constante;
J=squeeze(J);                          %Remover dimensiones
background = imopen(J,strel('disk',0)); %Apertura en morfología de
la imagen
I=wiener2(background,[4 4]);           %Eliminar ruido
imshow(I),title('Imagen Realce')      %Visualizar la imagen
```

Para realizar esta tarea de realce automáticamente, se utiliza la interfaz gráfica implementada, en la cual se configuró un *push-button* denominado realce.

Para el pre-procesamiento de la imagen termográfica se utilizó los comandos que se explican a continuación:

- **imadjust:** Ajuste para mejorar el contraste de la imagen, MATLAB cuenta con la función **imadjust**, ya sea para aumentarlo, reducirlo o ajustarlo. [44]. Esta función mapea los valores de la imagen I a nuevos valores. Es posible delimitar a los límites con la matriz vacía $[\]$ que significaría configurar a los límites como los considerados permisibles para ese tipo de imagen $[0,1]$.

Existen algunas variantes adicionales de esta función en las que aparte de considerar el aumento del contraste permiten escalar aún más el contraste mediante un parámetro (gamma), el cual permite representar la forma en la que se encontrarán relacionadas las imágenes al ser escaladas como se visualiza en la Fig. 4.4:




Fig. 4.4 Mapeo disponible con el factor gamma (Tomado de: [44])

- **imsubtract:** Resta dos imágenes o le resta una constante a una imagen
- **imadd:** Suma dos imágenes o le añade una constante a una imagen
- **strel:** Para crear un patrón o elemento estructurante, permite construir estructuras de referencia de diferente tamaño y forma.
- **imtophat:** Transformada de top-hat
- **squeeze:** Remover dimensiones
- **imopen:** Apertura en morfología
- **wiener2:** Filtro 2D para eliminar ruido [66]

- **Técnicas de filtrado**

Para facilitar esta tarea se ha implementado una lista de los filtros utilizados en esta tesis. El usuario puede seleccionar, cada uno de estos filtros de la lista de filtros disponible en la

GUI implementada en este trabajo, tales como: simétrico (espacial), pasa bajo, mediana y pasa alto

Filtros paso bajo

Las técnicas de filtrado en el dominio espacial operan directamente sobre los píxeles de la imagen mediante una máscara cuadrada o rectangular. Una máscara es una pequeña imagen que consiste en una serie de valores predeterminados para cada posición. La máscara se centra sobre el píxel de interés, de tal forma que el nuevo valor del píxel depende de los píxeles que cubren la máscara. El algoritmo utilizado para filtrar la imagen ha sido un filtro paso bajo y para ello, se ha utilizado la función *imfilter*, que requiere como parámetros una imagen **f**, la máscara del filtro (**w**).

Filtro *imfilter* simétrico

El siguiente código muestra cómo filtrar una imagen con una máscara de tamaño 5x5 de valores iguales, el cual se aplicó a la imagen de la Fig. 4.5 (b).

```
h = ones (5, 5) / 25; %Crea un filtro de tamaño 5x5, de valores
iguales (filtro promediado)
I2 = imfilter (I, h,'symmetric'); %Aplicar filtro a la imagen
utilizando imfilter
imshow(I2,[]), title('Filtro Simétrico')%Visualizar la imagen
```

Filtro pasa bajo

El código del filtrado pasa bajo que se aplicó a la imagen de la Fig. 4.5 (c) es el siguiente:

```
w=ones(3,3)/9; %Crea un filtro de tamaño 3x3, de valores iguales
(filtro promediado)
I2=imfilter(I,w); %Aplicar filtro a la imagen utilizando imfilter
imshow(I2), title(' Filtro pasa bajo')%Visualiza la imagen
```

En la Fig. 4.5 b) se puede observar los resultados obtenidos al aplicar este tipo de filtrado con la opción '*symmetric*', el cual permite una mejora en la nitidez de la imagen, y en c) los

resultados obtenidos mediante este filtro espacial (Filtro pasa bajo), mediante este filtro se suaviza y elimina el ruido que tiene la imagen.




Fig. 4.5 Aplicación de la función *imfilter* en matlab.

a) Imagen ROI completo IR_4978, b) Filtro *imfilter* simétrico, c) Filtro *imfilter* pasa bajo

Para construir la máscara del tipo de filtrado espacial lineal deseado se ha utilizado la función *fspecial*. Los distintos tipos de filtrado que se pueden aplicar y con los cuales se experimentó, se muestran en la Tabla 4.3.

Tabla 4.3 Sintaxis y parámetro la función *fspecial* para construir los tipos de filtrado

| Tipo | Definición | Sintaxis |
|-----------|---|---|
| 'average' | Filtro de media | <i>fspecial('average', [r c])</i> . Filtro de promediado rectangular de tamaño $r \times c$. Por defecto es 3×3 . Si en vez de $[r c]$ ponemos un simple número la matriz es cuadrada. |
| 'disk' | Filtro de media donde se da más importancia al píxel central | <i>fspecial('disk', r)</i> . Filtro de promedio circular (dentro de un cuadrado de tamaño $2r+1$) con radio r . El radio por defecto es 5 |
| 'log' | Filtro laplaciano de una gaussiana | <i>fspecial('log', [r c], sig)</i> . Laplaciano de un gaussiano (LoG) filtro de tamaño $r \times c$ y desviación estándar sig (positiva). Los valores predeterminados son 5×5 y 0.5. Si en vez de $[r c]$ ponemos un simple número la matriz es cuadrada |
| 'motion' | Filtro que crea sensación de movimiento en una imagen (de la cámara con respecto a la imagen) de len píxeles | <i>fspecial('motion', len, theta)</i> . La dirección del movimiento viene dada por $theta$, medido en grados. |
| 'prewitt' | Crea un filtro de <i>Prewitt</i> | $wv = fspecial('prewitt')$. Da salida a una máscara Prewitt 3×3 , wv , que se aproxima a un gradiente vertical. Para gradientes horizontales se gira la matriz (transponer): $wh = wv'$. |
| 'unsharp' | Crea un filtro 3×3 tipo <i>unsharp</i> | <i>fspecial('unsharp', alpha)</i> . El parámetro <i>alpha</i> controla la forma, este debe ser mayor que 0 y menor o igual a 1. El valor por defecto es 0,2. |

Tomado de: [56]

En este caso, se ha utilizado un filtro *fspecial* de tipo *unsharp*, cuyo código en matlab es el siguiente:

```
h = fspecial('unsharp');%Crea un filtro utilizando fspecial de tipo
unsharp
I2 = imfilter(I,h,'symmetric'); %Aplicar filtro a la imagen
utilizando imfilter
imshow(I2), title('Filtro pasa alto')%Visualiza la imagen
```

La Fig. 4.6 (b) muestra los resultados obtenidos al aplicar este tipo de filtro pasa alto, mediante el cual se mejora la nitidez y calidad visual de la imagen, además de resaltar los bordes.




Fig. 4.6 Implementación de la función *fspecial* en Matlab.
a) Imagen ROI completo IR_4978, b) Filtro *fspecial unsharp*, Filtro pasa alto

Filtrado de la mediana. El filtro de la mediana se define como el valor intermedio de la ordenación de los píxeles vecinos en función de su intensidad, con un tamaño de la ventana del filtro de 3x3, para evitar la pérdida de los detalles locales [67]. Para implementar este filtro se ha utilizado la función proporcionada por el *Toolbox* de matlab: *medfilt2*, el código en matlab es el siguiente:

```
I2 = medfilt2(I,[3 3]); %Aplicar filtro a la imagen utilizando
medfilt2 de tamaño 3x3
imshow(I2), title('Filtro mediana') %Visualizar la imagen
```

En la Fig. 4.7 (b) se visualiza los resultados al aplicar el filtro de la mediana el cual reduce el ruido y al mismo tiempo preserva los bordes.




Fig. 4.7 Implementación de la función *medfilt2* en matlab,
a) Imagen ROI completo IR_4978, b) Filtro mediana

4.2.4 Definición de los descriptores de textura simples

Análisis estadístico de texturas de imágenes médicas

El sistema de visión humano percibe escenas con variaciones de intensidad y color, las cuales forman ciertos patrones que se repiten, llamadas texturas. ACHARYA and RAY (2005) [68] definen a las texturas como:

- a) Un conjunto de patrones repetitivos, los cuales caracterizan a las superficies de varias clases de objetos. La clasificación de estos patrones resultará fácil si las texturas presentes en las imágenes se pueden identificar y diferenciar entre sí.
- b) Las texturas proporcionan información importante de la disposición de los elementos importantes de una imagen
- c) Los atributos de una textura se pueden describir en términos cualitativos como la homogeneidad, la orientación de las estructuras y la relación espacial entre las intensidades de la imagen. [68]

TEXTURA

Un método importante para la descripción de regiones consiste en cuantificar su contenido de textura. Aunque no existe una definición formal de textura, este descriptor proporciona intuitivamente medidas de propiedades tales como suavizado, rugosidad y regularidad [29].

Los tres métodos más utilizados en el procesado de imágenes para describir la textura de una región son los estadísticos, estructurales y espectrales. En este trabajo son utilizados los métodos estadísticos.

Los métodos estructurales tratan de la composición de primitivas de imágenes, tales como la descripción de texturas basadas en líneas paralelas regularmente espaciadas.

Los métodos espectrales se basan en propiedades del espectro de Fourier y se utilizan primordialmente para detectar la periodicidad global de una imagen mediante la identificación de picos estrechos de alta energía del espectro.

Los métodos estadísticos proporcionan características de textura tales como suavidad, rugosidad, granularidad y otras similares.

Descriptores estadísticos de texturas

El análisis estadístico de texturas calcula características paralelamente a cada punto en una imagen de textura y proporciona un conjunto de estadísticos de distribución de características locales. Las características locales son definidas por la combinación de intensidades en posiciones específicas relativas a cada punto en la imagen. Según el número de puntos que define la característica, los estadísticos son clasificados en estadísticos de primer orden, segundo orden y orden superior. Los métodos estadísticos proporcionan varias medidas de propiedades de la textura [53].

En el presente trabajo se consideraron características de primer orden, para calcular este tipo de descriptores se utiliza un histograma de probabilidades h_p obtenido al dividir cada valor del histograma original entre el número total de píxeles de la imagen. La formulación matemática de los descriptores de textura utilizados se especificó en la sección 2.2.10.5 A continuación se describen cada uno de los descriptores por modalidad.

Descriptores de primer orden

Miden la probabilidad de observar un valor de gris en un sitio elegido aleatoriamente en la imagen. Pueden ser calculados a través del histograma de una imagen. Estos descriptores no miden la relación entre píxeles [70].

Medidas de tendencia central

Dentro de las medidas de tendencia central se encuentra la media aritmética, la mediana y la moda. Estos descriptores de intensidad solo consideran la intensidad, $p(i; j)$, de cada píxel en la región, por lo que son los más simples y rápidos de obtener. Algunos descriptores de este tipo son [71, 17]:

Media: Es la medida de tendencia central más conocida. La media se calcula sumando todos los valores de una muestra y dividiendo entre el número de valores sumados, es decir, determina una media estimada de los niveles de gris en la región analizada [72].

Mediana: La mediana de un conjunto de valores es aquel valor que divide al conjunto en dos partes iguales, de forma que el número de valores mayores o iguales a la mediana es igual al número de valores menores o iguales a ésta. En este caso, la mediana ordena las intensidades de los píxeles, proporcionando el píxel medio cuando el número de píxeles es impar, de lo contrario proporciona el valor de los dos píxeles centrales divididos entre 2.

Moda: La moda es un conjunto o muestra, es aquel valor que ocurre con mayor frecuencia. Si todos los valores son diferentes no hay moda. Un conjunto de valores puede tener más de una moda. [73]

Medidas de dispersión

Una medida de dispersión nos indica la variabilidad que está presente en el conjunto de datos. A continuación se definen algunas medidas de dispersión [74]

Varianza: Es posible medir la dispersión en función de en cuanto están espaciados los datos con respecto a su media. [75]. Es decir, mide la disimilitud que hay entre la distribución de las intensidades de los píxeles con respecto a la media. [71, 17]:

El segundo momento o varianza, es de particular importancia para la descripción de la textura ya que proporciona una medida del contraste del nivel de gris, lo que se puede utilizar para establecer descriptores de suavidad. [76]

Momento de segundo orden (desviación estándar): Mide la dispersión o contraste entre los niveles digitales. Se identifica con la homogeneidad que se percibe en la imagen. La desviación determina la dispersión de intensidad en el objeto a estudiar [67].

Asimetría: Mide la distribución de las intensidades de los píxeles. Se puede visualizar una distribución simétrica, cuando se visualiza la misma cantidad de intensidad de píxeles a la izquierda y a la derecha, con respecto al punto central. Sin embargo, cuando la distribución se concentra hacia la izquierda se considera como negativa, y positiva cuando la distribución se concentra hacia la derecha. [71, 17]

La kurtosis o apuntamiento indica cómo se reparte el histograma entre la parte central y los extremos [72]. Cuanto mayor sea ese valor menos importancia tendrá la parte central. Es positivo si el pico en el histograma es más alto que el de una distribución normal. Si el pico es inferior, la kurtosis es negativa.

El coeficiente de asimetría γ_1 , que mide la desviación del histograma y es igual a 0 para histogramas simétricos, positivo para histogramas desplazados a la izquierda y negativo para los que se encuentran desplazados a la derecha. [76]

El coeficiente de kurtosis γ_2 , que mide el aplanamiento del histograma respecto a una distribución normal. Toma valor igual a 0 cuando tiene una distribución normal, valor positivo para una distribución más esbelta que la normal y valor negativo cuando es más aplanada que la normal.

La uniformidad U, proporciona información de lo uniforme que es la textura. Esta es máxima cuando todos los niveles de gris son iguales y disminuye cuanto más diferentes sean.

4.2.5. Segmentación de la región de interés

La segmentación de las regiones de interés después de ser extraídas mediante la herramienta denominada segmentador [50], se realizó el uso de dos métodos de segmentación: Método I y Método II. Dichos métodos se describe a continuación.

Método I, Umbralización simple

Matlab posee una función que es **im2bw(f, T)**, esta función realiza la binarización que consiste en obtener representado solo por dos tonos de color, blanco y negro generalmente, se debe especificar qué color se da a cada pixel esto se hace dando un umbral de binarización. Donde T es el umbral tal que todos los niveles de intensidad por debajo de **T** los hace 0 y todos los que son mayores que **T** los hace 1. Dicho umbral se puede obtener con la siguiente función la cual aplica el método de *Otsu*: $T = \text{graythresh}(f)$, para obtener automáticamente un umbral global optimo o se puede considerar un valor de umbral fijo elegido experimentalmente por el usuario o teniendo en cuenta la información del histograma, permitiendo evaluar con cuál de estas alternativas se obtiene los mejores resultados de la segmentación.

La segmentación basada en histograma, utiliza la información del histograma que representa el número de puntos de la imagen que posee cada valor de gris, en la Fig. 4.8, se indica el histograma normalizado de la imagen IR_4978 (ROI completo), en la cual se puede visualizar que los lóbulos indican zonas homogéneas, por lo que el valle establece el umbral de separación. Se estableció un umbral fijo con valor de 187, al dividir este umbral para 255 niveles de gris se obtiene el valor de 0.73. El valor del umbral fue seleccionado de manera experimental, mediante este umbral se puede separar el fondo del objeto.




Fig. 4.8 Histograma normalizado de la imagen IR_4978 (ROI completo)

El código implementado en matlab para segmentar la imagen por umbralización simple es el siguiente:

```

threshold =187; %Umbral fijo
BW=im2bw( I,threshold/255);%Binarización de la imagen mediante el
umbral de 187/255 (0.73)
BW=bwareaopen(BW,300); %Eliminar los objetos de la imagen binaria
conectados que tengan un número de píxeles igual a 300
boundary = bwperim(BW); %Devuelve la imagen binaria solo con los
píxeles del perímetro.
segmentResults = I; %Imagen original se asigna a otra variable para
obtener una imagen gray
segmentResults(boundary) =0;%Resalta los límites del resultado de
la segmentación
imshow(segmentResults) %Visualiza la imagen

```

Mediante este código se extrae la región de interés de la imagen original, la imagen binaria obtenida es convertida a una imagen en escala de grises (gray), para visualizar solo la segmentación realizada y poder extraer sus características en la siguiente etapa del procesamiento, en la Fig. 4.9. Se visualiza los resultados al aplicar el Método I. La región de interés es extraída de la imagen ROI completo IR_4978.




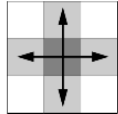

Fig. 4.9 Segmentación mediante *im2bw* con umbral 0.73.

a) Imagen ROI completo IR_4978, b) ROI completo, c) Mama Izquierda, d) Mama derecha

Para realizar la segmentación por umbralización se han utilizado las siguientes funciones en Matlab:

- La función *im2bw*, permite **transformar** la imagen en binaria mediante un umbral.
- La función *bwareaopen*, se utiliza para eliminar todos los objetos conectados que tengan un determinado número de **p** píxeles en las imágenes binarias, produciendo otra imagen binaria más óptima. La conectividad por defecto es 8 píxeles para la dimensión 2D, en la Tabla 4.4 se indica los tipos de conectividad posibles para 2D.

Tabla 4.4 Conectividad bidimensional

| Valor | Significado | Figura |
|-------|---|--|
| 4 | Vecindad de 4 píxeles: Un par de píxeles colindantes forman parte del mismo objeto solo si están activos y conectados vertical u horizontal, como se indica en la Fig. 4.10 |  <p>Fig. 4.10. Vecindad 4. [77]</p> |
| 8 | Vecindad de 8 píxeles: Un par de píxeles colindantes forman parte del mismo objeto solo si están activos (por defecto), como se indica en la Fig. 4.11 |  <p>Fig. 4.11. Vecindad 8. [77]</p> |

Tomado de: [77]

- *im2double*: Conversión de una imagen a doble

- ***bwperim***: Devuelve una imagen binaria solo con los píxeles del perímetro de los objetos de la imagen de entrada. Un píxel forma parte del perímetro si es distinto de cero y está conectado al menos a un cero (fondo). La conectividad por defecto es 4 para dos dimensiones
- ***boundary***: Para resaltar los límites o fronteras del resultado de la segmentación

Método II, Obtención de los máximos y mínimos regionales

Una aplicación muy interesante en morfología es la detección de máximos y mínimos regionales. Se define región máxima a un grupo de píxeles con conectividad entre sí, de forma que todos tienen el mismo valor y los píxeles externos a la región tienen valores menores. La región mínima se caracteriza por tener sus píxeles externos valores superiores a los suyos.

La toolbox para el procesamiento de imágenes en Matlab incluye varias funciones que se pueden utilizar para encontrar áreas de mayor o menor intensidad en una imagen. Mediante los máximos y mínimos regionales se agrupan los píxeles con mayor y menor intensidad, se reconstruye la imagen por dilatación para los máximos y mediante erosión para los mínimos, en este caso solo se utiliza la región máxima con los píxeles de mayor intensidad, esta región es extraída de la imagen, se convierte la imagen original a doble y se realiza una multiplicación con la imagen segmentada (superponer), para poder procesarla en la siguiente etapa, se realizan los mismos pasos explicados para la segmentación por umbralización.

El código utilizado para realizar la segmentación mediante el Método II se presenta a continuación:

```
imgRegMaxGris = I-imreconstruct(I-50,I); %Reconstruye la imagen,
mediante la máscara especificada
imgRegMinGris = imreconstruct(I,I+30)-I;
imgRegMax=imextendedmax(I,72); %Identifica todos los pixeles
máximos regionales conectados con un valor de intensidad constante
de 72, produciendo una imagen binaria de salida
```

```
imgRegMin=imextendedmin(I,30); %Identifica todos los pixeles
mínimos regionales conectados con un valor de intensidad constante
de 30, produciendo una imagen binaria de salida.
```

En la Fig. 4.12 se observa los resultados de la segmentación por máximos y mínimos regionales aplicado a las imágenes ROI completo, mama derecha y mama izquierda.




Fig. 4.12 Segmentación mediante máximos y mínimos regionales.

a) Imagen ROI completo IR_4978, b) ROI completo, c) Mama Izquierda, d) Mama derecha

Para la segmentación por máximos y mínimos regionales se utilizaron las funciones de Matlab:








- **imreconstruct:** Reconstruir una imagen, según una máscara especificada. [78]
- **imextendedmax e imextendedmin:** Transformada extendida máxima y mínima.

Un máximo o mínimo regional son un conjunto de píxeles conectados con un valor de intensidad constante y cuyos vecinos tienen un valor inferior o mayor. Estas funciones identifican áreas de una imagen en donde el cambio de intensidad sea extremo, tal que la diferencia entre el píxel y los píxeles vecinos sea mayor o menor que un cierto valor de umbral especificado. [79]

Comparación entre el Método I y Método II

La comparación de estos métodos se indica en la Tabla 4.5, en la cual se presenta algunas de las características de textura obtenidas, tales como la media, desviación estándar, uniformidad y el coeficiente de asimetría, para la imagen IR_4978

Tabla 4.5. Imagen IR-4978 y algunos valores de media, desviación estándar, uniformidad y coeficiente de asimetría

| Método I-Umbralización simple | | | | | | | |
|---|---|----------------|--------------|----------------------------|--------------------|------------------------|--|
| Termograma | Segmentación | Mamas | Media | Desviación estándar | Uniformidad | Coef. Asimetría | |
| IR_4978  |  | Mama Derecha | 43.9062 | 81.5875 | 0.5770 | 1.6175 | |
| |  | Mama Izquierda | 45.8713 | 87.8355 | 0.5959 | 1.6445 | |
| |  | ROI Completo | 90.2700 | 101.5353 | 0.2885 | 1.0473 | |
| | Método II-Máximos y mínimos regionales | | | | | | |
| |  | Mama Derecha | 43.9655 | 81.6720 | 0.5769 | 1.6165 | |
| |  | Mama Izquierda | 46.2398 | 88.0833 | 0.5933 | 1.6344 | |
|  | ROI Completo | 90.8007 | 101.6413 | 0.2861 | 1.0447 | | |

Tal como se puede observar en dicha tabla, existen diferencias en las características de textura entre el Método I y Método II, para el caso de la imagen IR_4978.

4.2.6. Extracción de los descriptores de textura simple de la región de interés (ROI)

Una región de una imagen puede revelar diferentes tipos de características de interés, esto se debe a que cada píxel puede almacenar diferentes tonalidades de colores que describen un objeto. El área de procesamiento de imágenes proporciona diversos métodos que permiten estudiar las propiedades que describen una región de la imagen.

De las imágenes segmentadas se obtiene el histograma normalizado, a partir de este se encuentra la media, mediana, moda, varianza, desviación estándar, suavidad, asimetría, coeficiente de asimetría, coeficiente de Kurtosis, los valores mínimo y máximo. Las funciones utilizadas en Matlab son las siguientes:

- **mean2:** Calcula la media aritmética de determinados valores de una matriz.
- **median:** Calcula la mediana de una muestra (matriz) específica.
- **mode:** El valor más frecuente en una muestra (matriz) específica
- **var:** Calcula la varianza de una muestra específica, es igual al cuadro de la desviación estándar corregida.
- **std:** Devuelve la desviación estándar de una matriz o muestra específica.
- **min y max:** Devuelve los valores extremos de una determinada muestra.
- **imhist:** Visualiza el histograma de una imagen [80]

El código para extraer algunas de las características de textura realizada en matlab es el siguiente:

```
%Obtener el histograma normalizado de la imagen(gray) obtenida al
realizar la segmentación por umbralización simple

h=imhist(segmentResults)/numel(segmentResults);

%Calcular la media de la imagen(gray) obtenida al realizar la
segmentación por umbralización simple

media = mean2(double(segmentResults));

%Se inicializa las variables y se crea un ciclo para obtener los
valores de varianza, asimetría, kurtosis, uniformidad, desviación
estándar, los coeficientes de asimetría y kurtosis, mediante la
aplicación de las fórmulas explicadas en la sección 2.2.10.5
```

```

varianza = 0;
asimetría = 0;
kurtosis = 0;
uniformidad = 0;
for i=0:255
    varianza = varianza + h(i+1)*((i-media)^2);
    asimetría = abs(asimetría + h(i+1)*((i-media)^3));
    kurtosis = kurtosis + h(i+1)*((i-media)^4);
    uniformidad = uniformidad + (h(i+1))^2;
end
desviacion = sqrt(varianza);
coefAsimetría =abs( asimetría/(desviacion^3));
coefKurtosis = abs(kurtosis/(desviacion^4) - 3);

```

Algunos de los valores obtenidos mediante este código se indican en la Tabla 4.8 y la Tabla 4.9

4.2.7. Clasificación

Los algoritmos de clasificación tiene como objetivo determinar a qué clase pertenece una instancia, que es descrita por un conjunto de atributos a una o varias clases basándose en la información proporcionada por un conjunto de datos previamente clasificados (conjunto de entrenamiento) [81]. Para este trabajo se contó con un conjunto de entrenamiento de 9 imágenes con patología (anormal) y 9 sin patología (normal). Es importante indicar que no se realiza el reconocimiento del tipo de patología, solo su clasificación. Existen dos etapas dentro de este tipo de clasificación: el entrenamiento o aprendizaje y la validación (clasificación). Para clasificar las imágenes, previamente se ha extraído un vector de características conformada por ocho parámetros de textura simple, se clasifican mediante la utilización de la técnica de clasificación supervisada K-NN, el algoritmo se describe a continuación.

El algoritmo K-NN clasifica casos basándose en su parecido con respecto a otros casos. Los casos parecidos están próximos y los que no lo son están alejados entre sí, lo que quiere decir que la distancia entre los dos casos es una medida de diferencia. Los casos que están más próximos entre sí se denominan vecinos. Cuando se presenta un nuevo caso, se calcula su distancia respecto a los casos del modelo y los clasifica donde los casos sean los más parecidos (los vecinos más próximos) se cuadran y el nuevo caso es incluido en la clase que

contiene el mayor número de vecinos más cercanos. El número de vecinos que se van a examinar está dado por el parámetro k. El algoritmo k-NN implementado es el siguiente.

1: Entrada: $D = \{(x_1, c_1), \dots, (x_n, c_n)\}$ (la imagen y su respectiva clase ya clasificadas)

$x = (x_1, \dots, x_n)$ (imagen o imágenes a clasificar, nuevo caso)

k=número de vecinos

2: Condición para toda imagen ya clasificada (x_i, c_i)

Calcular distancia= $d(x_i, x)$ (distancia Euclídea, porque es un valor pequeño)

Ordenar $distancia_i = (i = 1, \dots, n)$ (orden ascendente)

Guardar los k casos D_x^k ya clasificados más cercanos a x

3: Asignar a x la clase más frecuente en D_x^k [82, 83]

Para realizar esta tarea se implementó una función en Matlab, del clasificador K-NN. Dicho código es el siguiente:

%Se crea una función que tiene como entradas el vector de la imagen a clasificar datosmatriz, el grupo de entrenamiento preguntamatriz, y el número de vecinos k, como salida se tiene los índices y su respectiva distancia ordenados en forma ascendente, este código se basa en el algoritmo explicado anteriormente.

```
function [Indice, Dist]=kNearestNeighbors (datosmatriz, preguntamatriz,
k)
Indice =zeros (size (preguntamatriz,1), k);
Dist = Indice;
numDataVectors=size (datosmatriz,1);
numpreguntavectores=size (preguntamatriz,1);

for i=1:numpreguntavectores,
dist=sum (( repmat (preguntamatriz (i, :), numDataVectors, 1) -
datosmatriz).^2,2); %Calcula la distancia euclídea
[sortval sortpos]=sort (dist, 'ascend'); %Ordena de manera ascendente
las mínimas distancias
Indice (i, :)=sortpos (1:k); %Se crea un vector con los índices
Dist (i, :)=sqrt (sortval (1:k) ); %Se crea un vector con las
distancias
end
```

Etapa de clasificación

%Se crea una función de realce, segmentación, extracción de características, se aplica a la imagen de entrada a clasificar, se obtiene como resultado un vector con 8 parámetros.

```
v3=realce2 (rcompleto);
```

%Se crea una función que realiza el mismo paso que se mencionó anteriormente, se tiene 18 imágenes de entrenamiento (9 normal, 9 anormal), el resultado es una matriz de tamaño 18x8(18 imágenes y 8 parámetros de textura)

```
[v]=classific(1);
```

%Se crea una función, la cual tiene como entradas v3 la imagen a clasificar, v las imágenes de entrenamiento y como salida se tiene un valor que puede ser 0 (Anormal) o 1(Normal), se realiza una condición y se visualiza el resultado de la clasificación

```
[clasificacion]=KNN(v3,v);
```

```
if clasificacion==0
    disp('Anormal');
else
    disp ('Normal');
end
```

%Se crea una función, la cual tiene como entradas v3 la imagen a clasificar, v las imágenes de entrenamiento, se aplica la función kNearestNeighbors, con k=1, para obtener las distancias y su respectivo índice, seguidamente se encuentra la mínima distancia y su índice, mediante el valor del índice se clasifica a la imagen con un 0 o 1

```
function [clasificacion]=KNN(v3,v)
```

```
[vecinos ,distancias]=kNearestNeighbors(v3',v,1);
[Md ,In ] = min( distancias);
if In >= 1 && In<=9
    clasificacion=0;
else
    clasificacion=1;
end
```

En la Fig. 4.13. Se observa el resultado de aplicar este clasificador para la clasificación de la imagen IR-4978, cuyo valor es de ANORMAL.

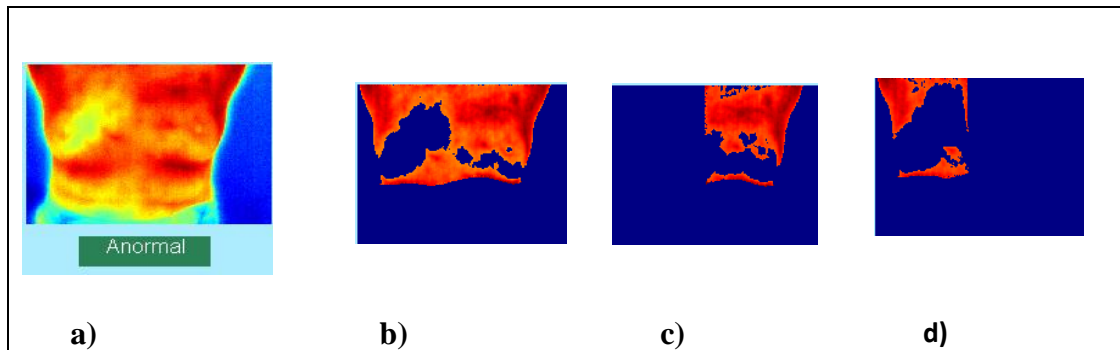


Fig. 4.13 Clasificación K-NN de la imagen IR_4978, a) Imagen ROI completo IR_4978, b) ROI completo, c) Mama Izquierda, d) Mama derecha

4.2.8. Evaluación del clasificador

Para la evaluación del clasificador se utilizó un conjunto de 18 imágenes de test, y 18 imágenes de entrenamiento. Se realiza la asignación de las clases. Se encuentra el número de TP, TN, FP y FN se construye una matriz de confusión. Además, para evaluar el desempeño del clasificador se utilizó las siguientes métricas: exactitud, precisión, cobertura (sensibilidad), medida $-F$ y la especificidad, cuya formulación matemática se presenta en el capítulo II.

El código implementado en matlab para evaluar el rendimiento del clasificador es el siguiente:

%Se crea una función para leer la dirección de la carpeta en la que se encuentran las imágenes para el entrenamiento del sistema (9 imágenes sanas y 9 enfermas), además se convierte la imagen de RGB a gray, se aplica la función de realce al grupo de imágenes de entrenamiento de manera similar se realiza para las imágenes de test

```
function [test]=testclass(rgb)
Raiz = 'test2';
DirTrain = 'imagenes';
TrainFiles = dir([Raiz '/' DirTrain]);
Train_Number = (size(TrainFiles,1) - 2);
for i = 3 : Train_Number+1
    nombre = TrainFiles(i).name;
    img = imread([Raiz '/' DirTrain '/' nombre]);
    if(rgb==0)
        img=rgb2gray(img);
    else
        img=img(:,:,rgb);
    end
end
```



```

        end
        testData(i-2,:) = img(:);
        [test(i-2,:)] = realce2(img);
    end

test]=testclass(1);% imagen test
[v]=classific(1);% imagen entrenamiento (train)

%Función para la clasificación de las imágenes de test mediante las
imágenes de entrenamiento

[idxstest distanciasstest]=kNearestNeighbors(v,test,1);

%Se crea un vector con la clase correspondiente a cada imagen de
entrenamiento (9 anormales y 9 normales)

trainClass=[0; 0; 0;0; 0; 0; 0; 0; 0; 0; 1; 1; 1; 1; 1; 1; 1; 1; 1;1];)

%Se crea un vector con la clase correspondiente a cada imagen de
test (9 anormales y 9 normales) intercaladas

testClass =[0; 1; 0;1; 0; 1; 0; 1; 0; 1; 0; 1; 0; 1; 0; 1; 0;1];

K = 1; % vecino
D2 = distanciasstest(:,1:K);
idx = idxstest(:,1:K);

prediction= mode(trainClass(idx),2); % asignación de clases
C = confusionmat(testClass, prediction); % creación de la matriz de
confusión, se calcula algunas de las medidas de evaluación
explicadas en la sección 2.2.10.7
err = sum(C(:)) - sum(diag(C)); %Calcular el error
accuracy = 100 * sum( testClass== prediction)/length(testClass);
%calcular la exactitud
disp('Clasificador KNN') %Viaualizar los valores
fprintf('Exactitud: %.2f%%\n', accuracy)
fprintf('Error: %.2f\n',err )

```

En la Tabla 4.6 se indica los valores de cada medida de calidad obtenidos al realizar la tarea de evaluación del clasificador, para el Método I de segmentación, mediante la utilización del código realizado en matlab

Tabla 4.6 Medidas de calidad (Método I)

| Clasificador K-NN | | | |
|---------------------------|-------------------|----------------------------|--------------|
| Medidas de Calidad | Porcentaje | Matriz de confusión | Valor |
| Precisión | 100 % | TP | 8.00 |
| Exactitud | 94.44 % | TN | 9.00 |
| Cobertura | 88.90 % | FP | 0.00 |
| Medida-F | 94.10 % | FN | 1.00 |
| Especificidad | 100 % | TPR | 0.889 |
| Error | 1 | FPR | 0.00 |

Elaborado por la investigadora

4.3 Validación de los resultados

La validación de los resultados de los algoritmos de clasificación se efectuó mediante dos métricas: La evaluación de la calidad cualitativa y cuantitativa.

Validación Cualitativa

Para realizar la validación cualitativa se ha tenido en cuenta la evaluación de la calidad visual y el conocimiento proporcionado por el grupo de expertos médicos del hospital SOLCA y los grupos de expertos de las distintas universidades que conforman el grupo de investigación del proyecto: “Sistema de Ayuda al Diagnóstico en Mastología basado en el Análisis de Imágenes Térmicas”. En el Anexo A.3, se aporta un certificado de la valoración de los resultados obtenidos por expertos médicos de la Unidad Oncológica SOLCA, quienes a su vez serán los futuros usuarios del sistema.

Validación Cuantitativa

Para realizar este paso se hizo uso de las métricas de especificidad, sensibilidad y de exactitud definidas en la sección 2.2.10.7. “EVALUACIÓN” y se experimentó con 18 imágenes de test, de los cuales 9 casos están diagnosticados como anormales y 9 como

normales, tal como se muestra en la Tabla 4.7, en la cual se puede observar en los resultados obtenidos para el Método I, de 9 casos normales, 8 aciertos (94.44%) y 1 fallo. Para los casos anormales 9 aciertos (100%) y cero fallos.

Tabla 4.7. Resultado de aciertos y fallos para casos normales y anormales utilizando K-NN (Método I)

| Enfermedad | Casos | Aciertos | Fallos | % aciertos | % fallos |
|-------------------|--------------|-----------------|---------------|-------------------|-----------------|
| Anormal | 9 | 9 | 0 | 100% | 0% |
| Normal | 9 | 8 | 1 | 88.88% | 11.11% |
| Total | 18 | 17 | 1 | 94.44% | 5.55% |

En cambio en la Tabla 4.8 se puede observar los resultados obtenidos para el Método II, de 9 casos normales, 7 aciertos (88.88%) y 2 fallos (11.11%). Para los casos anormales 9 aciertos (100%) y cero fallos.

Tabla 4.8. Resultado de aciertos y fallos para casos normales y anormales utilizando K-NN (Método II)

| Enfermedad | Casos | Aciertos | Fallos | % aciertos | % fallos |
|-------------------|--------------|-----------------|---------------|-------------------|-----------------|
| Anormal | 9 | 9 | 0 | 100% | 0% |
| Normal | 9 | 7 | 2 | 77.77% | 22.22% |
| Total | 18 | 16 | 2 | 88.88% | 11.11% |

Al realizar la comparación del Método I y el Método II, se propone el uso del primer método, el cual fue utilizado en esta TEMI, ya que con dicho método se producen menos errores en la clasificación.

Teniendo en cuenta estos valores (Método I), el especialista médico consideró que la sensibilidad y especificidad obtenidas son resultados importantes y proporcionan información acertada y coherente según el diagnóstico de la paciente y de su clasificación como normal o anormal, tal como se puede observar en las Tablas 4.6 y 4.7. Además, de realizar un análisis de los parámetros de textura simples de asimetría y uniformidad, para observar las diferencias entre las mamas derechas e izquierdas, considerando que dichos valores no difieren en gran medida cuando existe alguna patología.

La imágenes que se utilizaron para el test, se muestran en la Tabla 4.9, en la cual se presentan algunas de las características de textura obtenidas, tales como la media, la desviación estándar, uniformidad y coeficiente de asimetría,...A partir de un umbral de 187 (0.73), para el grupo normal. Y en la Tabla 4.10, las del grupo anormal, a partir de un umbral de 187 (0.73).

Tabla 4.9. Imágenes de test y algunos valores de media, desviación estándar, uniformidad y coeficiente de asimetría para el grupo normal

| Termograma | Edad | Mamas | Media | Desviación estándar | Uniformidad | Coef. Asimetría |
|-------------------|-------------|----------------|--------------|----------------------------|--------------------|------------------------|
| IR_1366 | 54 | Mama Derecha | 32.7052 | 71.4647 | 0.6568 | 1.9772 |
| | | Mama Izquierda | 33.9733 | 71.9279 | 0.6408 | 1.9027 |
| IR_3689 | | Mama Derecha | 58.2149 | 89.5199 | 0.4698 | 1.3037 |
| | | Mama Izquierda | 58.8790 | 90.3882 | 0.4647 | 1.2968 |
| IR_3702 | 47 | Mama Derecha | 40.5500 | 76.4642 | 0.5836 | 1.6375 |
| | | Mama Izquierda | 34.9178 | 73.7092 | 0.6437 | 1.8528 |
| IR_8269 | | Mama Derecha | 49.9075 | 87.4978 | 0.5479 | 1.4865 |
| | | Mama Izquierda | 46.0973 | 86.0167 | 0.5829 | 1.5876 |
| IR_3849 | | Mama Derecha | 39.9147 | 74.6754 | 0.5827 | 1.6135 |
| | | Mama Izquierda | 37.5702 | 72.9292 | 0.5979 | 1.7027 |
| IR_3830 | 58 | Mama Derecha | 52.1381 | 81.6418 | 0.4784 | 1.3612 |
| | | Mama Izquierda | 40.1117 | 72.9354 | 0.5612 | 1.6020 |
| IR_0777 | 35 | Mama Derecha | 50.2518 | 87.7165 | 0.5415 | 1.4881 |
| | | Mama Izquierda | 42.8241 | 81.0441 | 0.5844 | 1.6416 |
| IR_3630 | 38 | Mama Derecha | 36.4426 | 73.7286 | 0.6229 | 1.7656 |
| | | Mama Izquierda | 48.6544 | 82.7553 | 0.5277 | 1.4486 |
| IR_0729 | 55 | Mama Derecha | 38.0859 | 76.7749 | 0.6211 | 1.7558 |
| | | Mama Izquierda | 40.4736 | 80.1034 | 0.6097 | 1.7205 |

Tabla 4.10. Imágenes de test y algunos valores de media, desviación estándar, uniformidad y coeficiente de asimetría para el grupo anormal

| Termograma | Edad | Diagnóstico | Mamas | Media | Desviación estándar | Uniformidad | Coef. Asimetría |
|-------------------|-------------|---|----------------|--------------|----------------------------|--------------------|------------------------|
| IR_1270 | 33 | Quiste ME | Mama Derecha | 53.4699 | 93.0889 | 0.5441 | 1.4725 |
| | | | Mama Izquierda | 59.1214 | 94.8153 | 0.4946 | 1.3511 |
| IR_2942 | 43 | Fibroadenoma ME | Mama Derecha | 36.2104 | 65.3500 | 0.5519 | 1.6388 |
| | | | Mama Izquierda | 37.4394 | 68.2282 | 0.5590 | 1.6381 |
| IR_7464 | | Carcinoma ductal invasivo con áreas de alto grado de necrosis, 2,9x2,2x0,4 | Mama Derecha | 42.1438 | 83.4827 | 0.6126 | 1.7060 |
| | | | Mama Izquierda | 50.4001 | 88.0885 | 0.5432 | 1.4828 |
| IR_3727 | | Carcinoma ductal invasivo | Mama Derecha | 41.5697 | 77.5551 | 0.5694 | 1.6632 |
| | | | Mama Izquierda | 53.1863 | 86.5859 | 0.4977 | 1.3891 |
| IR_1353 | | No disponible | Mama Derecha | 52.4014 | 88.0665 | 0.5255 | 1.4109 |
| | | | Mama Izquierda | 56.2420 | 89.5952 | 0.4945 | 1.3319 |
| IR_3437 | | Quiste bilateral | Mama Derecha | 45.0950 | 87.8202 | 0.6054 | 1.6637 |
| | | | Mama Izquierda | 41.8866 | 84.4091 | 0.6238 | 1.7294 |
| IR_5563 | 25 | Fibroadenoma ME | Mama Derecha | 65.7840 | 100.0123 | 0.4683 | 1.2698 |
| | | | Mama Izquierda | 37.7875 | 81.0600 | 0.6543 | 1.8682 |
| IR_1026 | 61 | Carcinoma ductal invasivo, grado intermedio histológico, el carcinoma intraductal y peritumoral, 3 nódulos, la mayoría de 2,5x2,2 | Mama Derecha | 39.9788 | 81.7176 | 0.6298 | 1.7751 |
| | | | Mama Izquierda | 54.6965 | 90.6154 | 0.5141 | 1.4042 |
| IR_4910 | 56 | Liquidación, MG ME BIRADS 1, MD BIRADS 2 | Mama Derecha | 34.4498 | 69.9041 | 0.6212 | 1.8140 |
| | | | Mama Izquierda | 31.7840 | 68.2805 | 0.6534 | 1.8999 |

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

- Las imágenes termográficas son una técnica de diagnóstico precoz que en comparación con otras técnicas no tienen ningún riesgo, no tiene tocamientos a la paciente y es totalmente no invasiva y de bajo costo. Además pueden detectar el inicio varios años antes que cualquier otra técnica.
- La caracterización de la asimetría ayuda a establecer diferencias y a encontrar indicadores de procesos la presencia o ausencia de anomalías. Mediante los cambios de temperatura, se puede proporcionar información relevante para la prevención de cáncer de seno.
- La aplicación de la etapa del pre-procesamiento de las imágenes termográficas utilizadas (ver anexo A.2), contribuye a resaltar la región de interés, además de mejorar la imagen para su posterior etapa de procesamiento.
- La textura es una característica importante utilizada en la identificación de objetos o regiones de interés en una imagen que caracterizan de forma estadística la textura de la imagen, tales como la media, la desviación típica, el coeficiente de asimetría, el coeficiente de *kurtosis*, y la uniformidad, los cuales se utilizaron para que el sistema infiriera la clasificación de las misma, a partir del vector de características constituido con dichos parámetros durante la etapa de aprendizaje y la evaluación del clasificador.
- Una vez efectuadas las pruebas experimentales se ha podido comprobar que la técnica de segmentación por umbralización es mejor respecto a la técnica de mínimos y máximos regionales con la que se comparó.

- El clasificador K-NN es una de las técnicas muy utilizadas para este tipo de tareas, ya que proporciona buenos resultados y conlleva poca complejidad. Usando este clasificador se obtuvo una clasificación mediante la métrica de exactitud de un 94.44 %, el cual corresponde al porcentaje de verdaderos positivos y el 5.55% de falsos positivos, para más detalles puede consultar la Tabla 4.5. Otros valores que pueden dar indicios de una buena clasificación son la asimetría, esta indica los valores obtenidos con la métrica de especificidad fue del 100 % y que la sensibilidad o cobertura fue del 88.90 %

5.2 Recomendaciones

- Para la adquisición de imágenes termográficas se debe aplicar de forma más rigurosa distintos protocolos existentes en la literatura y realizar una comparativa sobre los mismos y buscar de esta manera cual da mejor resultado. Así mismo, evaluar la adquisición desde las diferentes vistas: lateral, coronal y sagital.
- Se recomienda hacer más evaluaciones utilizando una muestra más representativa imágenes con diversos tipos de patologías.
- Experimentar con otros algoritmos tales como la matriz de co-ocurrencia de niveles de gris, métodos estructurales o métodos espectrales y así potenciar y enriquecer el sistema de ayuda al diagnóstico.
- Se recomienda como trabajos futuros disponer de una base de datos de imágenes termográficas para poder almacenar de manera más eficiente las imágenes con diagnóstico normal y anormal para la etapa del entrenamiento del clasificador, para obtener una mayor precisión en la clasificación de las imágenes.
- Como trabajos futuros se propone comparar los resultados obtenidos mediante del clasificador KNN implementado en esta tesis, con otros clasificadores, tales como las máquinas de soporte vectorial (SVM) o las redes neuronales y así aumentar la fiabilidad del desempeño del mismo, en el ámbito médico.

REFERENCIAS

- [1] Vivien David Tsu, Jose Jeronimo & Benjamin O Anderson. Boletín de la Organización Mundial de la Salud. Por qué es el momento adecuado para hacer frente al cáncer de mama y de cuello uterino en entornos con recursos escasos. Disponible en: <http://www.who.int/bulletin/volumes/91/9/12-116020-ab/es/>
- [2] Wishart GC, Campisi M, Boswell M, Chapman D, Shackleton V, Iddles S, et al. The accuracy of digital infrared imaging for breast cancer detection in women undergoing breast biopsy. *Eur J Surg Oncol*. 2010; vol. 36, pp. 535-40.
- [3] Ng EYK, "A review of thermography as promising non-invasive detection modality for breast tumor", *Int. J. Thermal Sciences*, vol. 48, pp. 849–859, 2008.
- [4] Fok SC, Ng EYK, Tai K. Early detection and visualisation of breast tumor with thermogram and neural network. *J Mech Med Biol*. 2002; vol. 2, pp. 185-95
- [5] Ng. EYK, Chen Y. Segmentation of breast thermogram: improved boundary detection with modified snake algorithm. *J Mech Med Biol*. 2006; vol. 6, pp. 123-36
- [6] Ng. EYK, Chen Y, Ung LN. Computerized breast thermography: study of image segmentation and temperature cyclic variations. *Int J Med Eng Technol*. 2001a; vol. 25, pp. 12-6.
- [7] Ng. EYK, Sudharsan NM. Numerical Modelling in conjunction with thermography as an adjunct tool for breast tumour detection. *BMC Cancer*. 2004; vol. 4, pp. 1-26.
- [8] EtehadTavakol M, Sadri S, Ng EYK. Application of K- and fuzzy c-means for color segmentation of thermal infrared breast images. *J Med Syst*. 2010; vol. 34, pp. 35-42
- [9] EtehadTavakol M, Ng EYK. Breast thermography as a potential non-contact method in the early detection of cancer: a review. *J Mech Biol*. 2013; vol. 13, pp. 1330001
- [10] Jakubowska T, Wiecek B, Wysocki M, Drews-Peszynski C. Thermal signatures for breast cancer screening - comparative study. In: *Engineering in Medicine and Biology Society (ed): Proceedings of the 25th Annual International Conference of the IEEE*, vol. 2, pp. 1117-20, 2003
- [11] Sowmya B, Bhattacharya S. Colour image segmentation using fuzzy clustering techniques and competitive neural network. *Appl Soft Comput.*; vol. 11, pp. 3170-8, 2011
- [12] Pakhira MK. A modified k-means algorithm to avoid empty clusters. *Int J Rec Trends Engin.*; vol. 1, pp. 220-6, 2009.
- [13] Tan JH, Ng EYK, Acharya UR. Study of normal ocular thermogram using textural parameters. *Infrared Phys Techn*. 2010; vol. 53, pp. 120-6
- [14] Acharya UR, Ng EYK, Tan JH, Sree SV. Thermography based breast cancer detection using texture features and support vector machine. *J Med Syst*. 2012; vol. 36, pp. 1503-10.
- [15] Ng EYK, Ung LN, Ng FC. Statistical analysis of healthy and malignant breast thermography. *J Med Eng Technol* 2001b; vol. 25, pp. 253-63
- [16] Keyserlingk JR, Ahlgren PD, Yu E, Belliveau N. Infrared imaging of the breast initial reappraisal using high resolution digital technology in 100 successive cases of stage I and II breast cancer. *Breast J*. 1998; vol. 4, pp. 245-51
- [17] Gonzales, Rafael y Woods, Richard. "Tratamiento Digital de Imágenes". Madrid: Addison-Wesley, 1996. 0-201-62576-8
- [18] Coleman MP et al. Cancer survival in five continents: a worldwide population-based study (CONCORD). *Lancet Oncol*, vol. 9, pp. 730–56, 2008.
- [19] John EM, Phipps AI, Davis A, Koo J. Migration history, acculturation, and breast cancer risk in Hispanic women. *Cancer Epidemiol Biomarkers Prev.*; vol. 14, No. 12, pp. 2905-2913, 2005.
- [20] Agencia Pública de Noticias del Ecuador y Suramérica andes "Quito registra el índice más alto de incidencia de cáncer de mama en Ecuador" [Online]. Disponible en: <http://www.andes.info.ec/es/noticias/quito-registra-indice-mas-alto-incidencia-cancer-mama-ecuador.html>. Consultado el 20 de abril de 2014
- [21] las #mamografías causan #cáncer de #mama (y otros hechos de #cáncer que probablemente nunca lo sabían. 2014, febrero [Online]. Disponible en: <http://quitarvelo.wordpress.com/2014/02/26/las-mamografias-causan-cancer-de-mama-y-otros-hechos-de-cancer-que-probablemente-nunca-lo-sabian/>. Consultado el 30 de abril de 2014

- [22] Jokerphd, Las #mamografías causan #cáncer de #mama (y otros hechos de #cáncer que probablemente nunca lo sabían). Disponible en: <http://quitarvelo.wordpress.com/2014/02/26/las-mamografias-causan-cancer-de-mama-y-otros-hechos-de-cancer-que-probablemente-nunca-lo-sabian/>. 26 febrero, 2014.
- [23] <http://www.elnuevoglobo.com/2012/index.php/todas-las-noticias/3038-solca-presenta-datos-oficiales-sobre-el-cancer-de-mama-en-ecuador>.
- [24] María Yaneli Ameza Alducin. “Validación Cuantitativa de Información Termográfica para el Pre-diagnóstico de Cáncer de Mama” Laboratorio Nacional de Informática Avanzada. Maestría en Computación Aplicada, 17 de Diciembre de 2012.
- [25] J Massa, P. Escobar, M. Del Fresno, M. Santiago 4, E. Arguiñarena, “Segmentación y caracterización en imágenes termográficas para diagnóstico de lesiones mamarias”, trabajo presentado en XVIII Congreso Argentino de Bioingeniería SABI 2011 - VII Jornadas de Ingeniería Clínica Mar del Plata, 28 al 30 de septiembre de 2011. Disponible en: <http://www.nivelatermografia.net/termografia>
- [26] Nivel, Equipos de Topografía, Acústica y Termograma [Online]. Disponible en: <http://www.nivelatermografia.net/termografia>. Consultado el 2 de abril de 2014
- [27] Etehad Tavakol M., Sadri S., and Ng E.Y.K. Application of k- and fuzzy c-means for color segmentation of thermal infrared breast images. *Journal of Medical Systems*, vol. 34, pp. 35-42, 2010.
- [28] International Academy of Clinical Thermology. What is breast thermography? [Online]. Disponible en: <http://www.iact-org.org/patients/breastthermography/what-is-breast-therm.html>, 2010. Consultado el 10 de mayo de 2014
- [29] Natalia Sánchez Aldana y Juliana Velásquez Gómez. “Imágenes por radiación infrarroja y termografía”. Escuela de Ingeniería de Antioquia (EIA) e Instituto de Ciencias de la Salud (CES).
- [30] Guía de termografía para mantenimiento predictivo. Copyright 2011, FLIR Systems AB. [Online] Disponible en: http://www.flirmedia.com/MMC/THG/Brochures/T820264/T820264_ES.pdf. Consultado el 20 de mayo de 2014
- [31] S. C. Liew. “Electromagnetic Waves”. Centre for Remote Imaging, Sensing and Processing.
- [32] H. Qi, P.T. Kuruganti, W.E. Snyder, “Detecting Breast Cancer from Thermal Infrared Images by Asymmetry Analysis”. In: Diakides, N. A. and Bronzino, J. D., *Medical Infrared Imaging*. (2008), pp. 27.1-27.14 [Online]. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.64.503&rep=rep1&type=pdf>. Consultado el 20 de junio de 2014
- [33] Brandan M.E. and Villaseñor N.Y. Detección del cáncer de mama: Estado de la mamografía en México. *Revista del Instituto Nacional de Cancerología*, pp. 147-162, 2006.
- [34] J.L. Griffin, D. Perlman, “Detección de Cáncer de Mama en Mujeres con Riesgo Promedio y Alto” (en español), *Obstetrics & Gynecology*, vol. 116, pp. 1410–1421, 2010.
- [35] Breast cancer screening and diagnosis. National Comprehensive Cancer Network practical guidelines in oncology. Ft. Washington (PA): National Comprehensive Cancer Network; 2009.
- [36] http://www.quimicanuclear.org/pdf_memorias2007/simposium/alonso_simposium.pdf. Consultado el 20 de julio de 2014
- [37] Castells X, Sala M, Ascunce N, Salas D, Zubizarreta R, Casamitjana M, et al. Descripción del cribado del cáncer en España. Proyecto DESCRIC. Madrid: Plan de Calidad para el Sistema Nacional de Salud. Ministerio de Sanidad y Consumo. Agencia de Evaluación de Tecnologías Sanitarias y Recerca Mediques de Catalunya; 2007. Informes de Evaluación de Tecnologías Sanitarias, AATRM núm. 2006 / 01.
- [38] Fred Alonso López Durán, Efraín Zamora Romo, José Luis Alonso Morales, “Tomografía por Emisión de Positrones: Los nuevos paradigmas”, Unidad PET–Ciclotrón, Pisano ED, Gatsonis C, Hendrick E, et al. *Diagnostic performance of digital versus film mammography for breast-cancer screening*. *New England Journal of Medicine* 2005; vol. 353, no. 17, pp. 1773-1783.
- [39] Image Processing Toolbox™ Users Guide MATLAB R2014a. Disponible en: http://www.mathworks.co.uk/help/pdf_doc/images/images_tb.pdf
- [40] G. Pajares (2008). *Visión por Computador, Imágenes Digitales y Aplicaciones*. 2da Ed. Editorial Alfaomega. México DF.
- [41] <http://www.ecci.edu.co/documents/direccionInvestigacion/20112/seminarios/telecomunicaciones/VisionArtificial.pdf>. Consultado el 28 de julio de 2014
- [42] Gonzales, Rafael, Woods, Richard y Eddins, Steven. “Digital Image Processing using Matlab” New Jersey: Prentice Hall, 2004. 0-13-008519-7.

- [43] García, Danilo. “Visión Artificial y Procesamiento digital de imágenes usando Matlab”. Ibarra: Pontificia Universidad católica del Ecuador, 2008.
- [44] Cuevas, Erick, Saldívar, Daniel y Pérez, Marco. “Procesamiento digital de imágenes con Matlab y Simulink”. México: Alfaomega Grupo Editor, 2010. 978-607707-030-6.
- [45] Zhou, Huiyu, Wu, Jiahua y Zhang, Jianguo. Digital Image Processing. s.l.: Bookboon.com, 2010. 987-87-7681-541-7.
- [46] Universidad Miguel Hernández, Servidor del Área de Ingeniería de Sistemas y Automática. [Online]. Disponible en: <http://www.isa.umh.es/ asignaturas/rvc/>. Consultado el 20 de noviembre de 2014
- [47] R. C. Gonzales and R. E. Woods. Tratamiento digital de imágenes. Addison-Wesley/Díaz de Santos, 1992.
- [48] Filtros. [Online]. Disponible en: <http://alojamientos.us.es/gtocom/pid/tema3-1.pdf>., consultado el 25 de noviembre de 2014.
- [49] Filtrado espacial, Trabocchi, Osvaldo y Sanfilippo, Fabian. Ingeniería de Control y Automatización Industrial. [Online]. Disponible en: <http://iaci.unq.edu.ar/materias/vision/archivos/apuntes/Filtrado%20Espacial.pdf>. Consultado el: 24 octubre de 2014.
- [50] R. S. Marqués, “Segmentação automática das mamas em imagens térmicas,” Dissertação de Mestrado, Universidade Federal Fluminense, Niterói-RJ, 2012.
- [51] Otsu, N. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, vol. 9, no. 1, pp. 62-66, 1979.
- [52] Gilbert Obed Arriaga Saavedra. “Detección de somnolencia, como asistencia para conductores, utilizando técnicas de procesamiento de imágenes”. Universidad Tecnológica del Perú. Facultad de Ingeniería Electrónica y Mecatrónica. Escuela de Ingeniería Electrónica. Lima-Perú 2012
- [53] Extracción de características de textura basada en la transformada wavelet discreta [Online]. Capítulo 3, Escuela Superior de Ingenieros de la Universidad de Sevilla. Disponible en: Web:<http://bibing.us.es/proyectos/abreproy/11494/fichero/PROYECTO%252FCapitulo+3.pdf>. Consultado el 10 de noviembre
- [54] Haralick, R.M., Shanmugan, k. Y Dinstein, I. (1973). Texture features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, U.S.A, vol. SMC-3, n° 6, pp. 610-521.
- [55] J Martínez, Elena. Análisis de Texturas [Online]. Capítulo 5.4, curso de visión computacional, dpto. de Ciencias de la Computación, Universidad Nacional de México, 2008. Disponible en: <http://turing.iimas.unam.mx/~elena/CompVis/Chapter5-4.pdf.gz>
- [56] R. C. Gonzalez, R.E. Woods y S.L. Eddins (2004). Digital image processing using matlab. Ed. PrenticeHall, 2004.
- [57] Sánchez Calle, Ángel y Moreno Díaz, Ana Belén. Características de los patrones percibidos por un SVA. Apuntes de Visión Artificial, Ingeniería Informática, Universidad Rey Juan Carlos, 2008. [Online]. Disponible en: <http://www.gavab.es/wiki/download/va/temario/tema4>. Consultado el 17 de junio de 2014
- [58] Dourado Lema, Juan Manuel y Calvo Estévez, Rosa María. Reconocimiento de objetos [Online]. Grupo de visión artificial y reconocimiento de patrones (VARPA), Universidad de A Coruña, 2007. Disponible en: <http://varpa.lfcia.org/Docencia/VAFiles/Curso0607/tema5.pdf>. Consultado el 18 de julio de 2014
- [59] Belur V. Dasarathy, “Nearest Neighbor (NN) Norms: NN Pattern Classification Techniques”, 1991
- [60] Moujahid, Abdelmalik, Inza Iñaki y Larrañaga Pedro. Clasificadores K-NN [Online]. Dpto. de Ciencias de la Computación e Inteligencia Artificial, Universidad del País Vasco, 2007. Disponible en: <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t9knn.pdf>
- [61] T. Hastie, R. Tibshirani, and J. H. Friedman, *The elements of statistical learning data mining, inference, and prediction*. New York: Springer, 2009.
- [62] Breast Thermography. Medical Infrared Imaging. Breast Cancer and Early Detection. Disponible en: http://www.breastthermography.com/case_studies.htm
- [63] UFF, “Database for Mastological Image,” 2012. [Online]. Disponible en: <http://visual.ic.uff.br/dmi/>. Consultado el 27 de octubre.

- [64] Inc. FLIR System. Termacam researcher profesional 2.9. [Online]. Disponible en: [http://support.flir.com/DocDownload/Assets/47/English/T559009\protect\(T1\textdollar387.pdf](http://support.flir.com/DocDownload/Assets/47/English/T559009\protect(T1\textdollar387.pdf), Consultado el 19 de octubre de 2014
- [65] UFPE, “Banco de imagens térmicas e proutuários eletrônicos,” 2010. [Online]. Disponible en: <http://150.161.110.168/termo>. Consultado el 14 de octubre de 2014
- [66] Matlab and Image Processing Toolbox release. Natick, MA: The MathWorkd, Inc., 2012.
- [67] Platero Dueñas, Carlos. Técnicas de preprocesado [Online]. Capítulo 4 de la asignatura de visión artificial, dpto. de Electrónica, Automática e Informática Industrial (ELAI), Universidad Politécnica de Madrid, 2007 [Online]. Disponible en: <http://www.elai.upm.es/spain/Asignaturas/Robotica/ApuntesVA/cap4Procesadov1.pdf>. Consultado el 11 de noviembre
- [68] Acharya T. and Ray A. K. (2005). Image Processing. Principles and Applications, Ed. John Wiley & Sons, USA.
- [69] Tomita Fumiaki and Tsuji Saburo. “*Computer Analysis of Visual Textures*”. Kluwer Academic Publishers. Massachusetts, United States of America. 1990.
- [70] Vergara Villegas Osslan Osiris. “Reconocimiento de Texturas Artificiales, Aplicación a la Inspección Visual”. Tesis de Maestría en Ciencias en Ciencias Computacionales. Centro Nacional de Investigación y Desarrollo Tecnológico. Cuernavaca, Morelos, Abril, 2003.
- [71] HD Cheng, XJ Shi, Rui Min, LM Hu, XP Cai, and HN Du. Approaches for automated detection and classification of masses in mammograms. Pattern recognition, vol. 39, no. 4, pp. 646-668, 2006.
- [72] De la Escalera Hueso Arturo. “Visión por Computador”, Fundamentos y métodos. Prentice Hall. Madrid, España. 2001.
- [73] Fernández Fernández S., Cordero Sánchez J. M., and Córdoba Largo A. Estadística Descriptiva. ESIC, 2002
- [74] Alea Riera V., Guillén M., Muñoz C., Torrelles E., and Viladomiu N. Estadística descriptiva. Aplicaciones prácticas. Universidad de Barcelona, 2001
- [75] Wayne W. D. Bioestadística Base para el análisis de las ciencias de la salud. Richard Stratton, 2009
- [76] Ortiz Rodríguez, Alberto. Tema 9: Texturas y descriptores de regiones [Online]. Apuntes de Visión Industrial, Ingeniería Técnica Industrial especialidad en Electrónica, Universidad de las Islas Baleares, enero de 2008. Disponible en Web: <http://dmi.uib.es/~aortiz/4730-tema9.pdf>. Consultado el 22 de junio de 2014
- [77] Eduardo Laorden Fiter, Descripción, comparación y ejemplos de uso de las funciones de la toolbox de procesado digital de imágenes de MATLAB^(R). Escuela Universitaria de Ingeniería Técnica de Telecomunicaciones Universidad Politécnica de Madrid. Proyecto Fin de Carrera (Plan 2000). Septiembre 2012. PFC_EDUARDO_LAORDEN_FITER_BMATLAB.pdf
- [78] Vincent, L., “*Morphological Grayscale Reconstruction in Image Analysis: Applications and Efficient Algorithms*,” IEEE Transactions on Image Processing, vol. 2, no. 2, April, 1993, pp. 176-201.
- [79] Soille, P., *Morphological Image Analysis: Principles and Applications*, Springer-Verlag, 1999, pp. 170-171
- [80] Cristian Gerardo Gil Sánchez y Miller Giovanni Franco Lemus. Análisis estadístico en MATLAB. Universidad Nacional Colombia. Facultad de Ciencias Económicas. Unidad de Informática y Comunicaciones. Bogotá D.C. Febrero 2005
- [81] Mitchell T. M. Machine Learning. MIT Press and the McGrawHill Companies, Inc., 2003.
- [82] F.M. Knaul, G. Nigenda, R Lozano, O.H. Arreola, A. Langer, and J. Frenk, Breast cancer in mexico: a pressing priority. Journal of Midwifery, Women’s Health, 16:113-123, 2008.
- [83] Juan Rodríguez Povedano. Anotación automática de imágenes. Universidad Carlos III de Madrid. Escuela Politécnica Superior. Ingeniería Técnica de Telecomunicaciones Especialidad en Imagen y Sonido. Madrid, Octubre 2010

ANEXOS

Anexo A: Imágenes termográficas utilizadas

A.1 Listado de termogramas

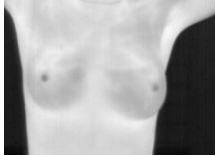
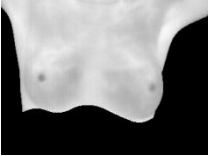
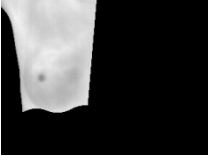
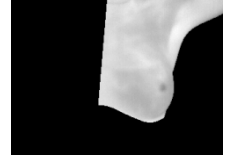

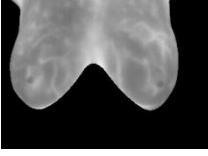
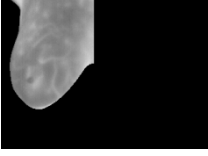



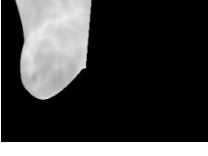
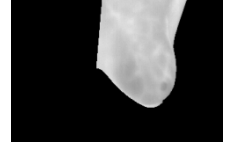














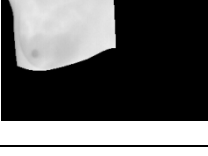

Tabla A.1.1 Listado de termogramas utilizados


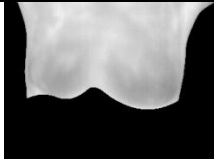

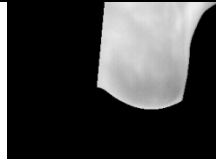
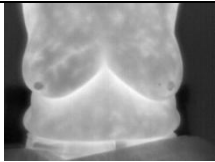
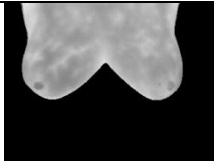
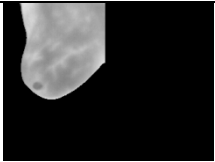
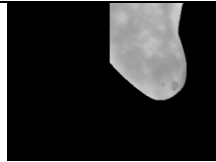
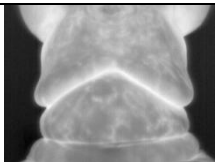

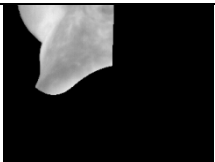
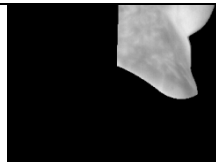
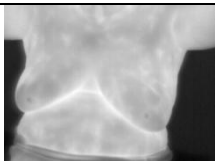
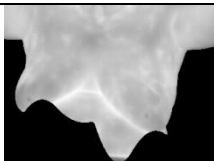
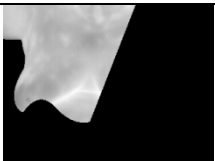
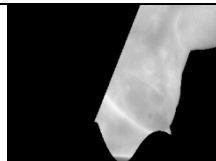
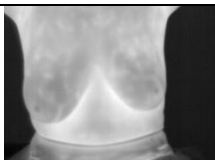
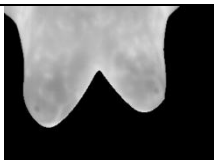
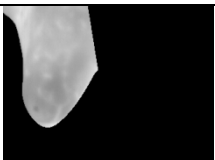
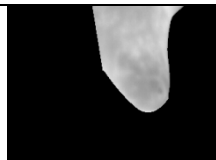

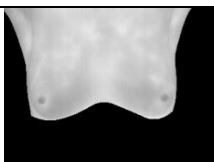
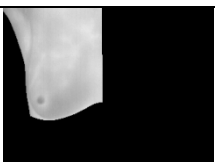
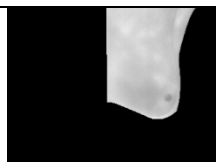
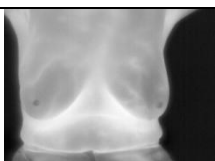
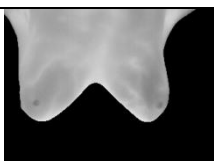
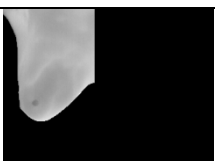
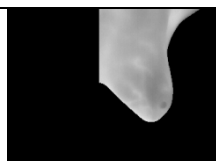
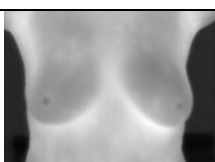
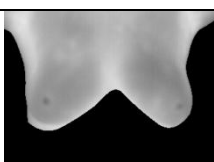
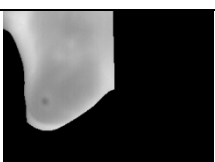
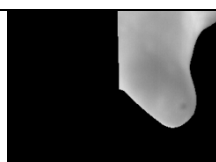
| Termograma (jpg) | Mama Izquierda | Mama Derecha | Situación |
|--------------------------|-----------------------|---------------------|------------------|
| IR_0089 | Saludable | Patológica | Patológica |
| IR_0159 | Saludable | Patológica | Patológica |
| IR_0432 | Patológica | Patológica | Patológica |
| IR_0716 | Patológica | Patológica | Patológica |
| IR_0729 | Saludable | Saludable | Saludable |
| IR_0737 | Saludable | Saludable | Saludable |
| IR_0756 | Patológica | Patológica | Patológica |
| IR_0768 | Patológica | Patológica | Patológica |
| IR_0777 | Saludable | Saludable | Saludable |
| IR_0787 | Saludable | Patológica | Patológica |
| IR_0947 | Patológica | Saludable | Patológica |
| IR_0965 | Patológica | Patológica | Patológica |
| IR_0968 | Patológica | Patológica | Patológica |
| IR_0973 | Saludable | Patológica | Patológica |
| IR_1000 | Patológica | Patológica | Patológica |
| IR_1026 | Saludable | Patológica | Patológica |
| IR_1270 | Patológica | Saludable | Patológica |
| IR_1336 | Saludable | Patológica | Patológica |
| IR_1353 | Saludable | Patológica | Patológica |
| IR_1366 | Saludable | Saludable | Saludable |
| IR_1632 | Saludable | Patológica | Patológica |

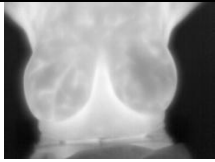
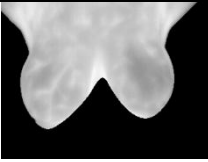
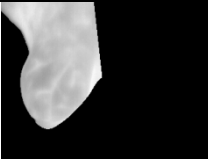
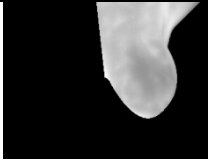


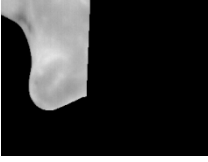





| | | | |
|----------------|------------|------------|------------|
| IR_2841 | Patológica | Saludable | Patológica |
| IR_2942 | Patológica | Saludable | Patológica |
| IR_3437 | Patológica | Patológica | Patológica |
| IR_3441 | Patológica | Saludable | Patológica |
| IR_3604 | Saludable | Patológica | Patológica |
| IR_3630 | Saludable | Saludable | Saludable |
| IR_3689 | Saludable | Saludable | Saludable |
| IR_3702 | Saludable | Saludable | Saludable |
| IR_3727 | Patológica | Saludable | Patológica |
| IR_3809 | Saludable | Patológica | Patológica |
| IR_3830 | Saludable | Saludable | Saludable |
| IR_3849 | Saludable | Saludable | Saludable |
| IR_3927 | Patológica | Patológica | Patológica |
| IR_3996 | Patológica | Saludable | Patológica |
| IR_4075 | Saludable | Saludable | Saludable |
| IR_4875 | Patológica | Saludable | Patológica |
| IR_4910 | Saludable | Patológica | Patológica |
| IR_4978 | Patológica | Saludable | Patológica |
| IR_5563 | Patológica | Saludable | Patológica |
| IR_5929 | Patológica | Saludable | Patológica |
| IR_7464 | Patológica | Patológica | Patológica |
| IR_8143 | Patológica | Patológica | Patológica |
| IR_8269 | Saludable | Saludable | Saludable |
| IR_8285 | Saludable | Patológica | Patológica |

A.2 Imágenes Test

Tabla A.2.1 Imágenes Test, 9 con una alteración en las mamas y 9 saludables

| Nombre | Imagen Original Patológicas | ROI completo | Mama Derecha | Mama Izquierda |
|---------|---|---|--|---|
| IR_1270 |  |  |  |  |
| IR_2942 |  |  |  |  |
| IR_7464 |  |  |  |  |
| IR_3727 |  |  |  |  |
| IR_1353 |  |  |  |  |
| IR_3437 |  |  |  |  |
| IR_5563 |  |  |  |  |

| | | | | |
|----------------|---|---|--|---|
| IR_1026 |  |  |  |  |
| IR_4910 |  |  |  |  |
| Nombre | Imagen Original Saludable | ROI completo | Mama Derecha | Mama Izquierda |
| IR_1366 |  |  |  |  |
| IR_3689 |  |  |  |  |
| IR_3702 |  |  |  |  |
| IR_8269 |  |  |  |  |
| IR_3849 |  |  |  |  |
| IR_3830 |  |  |  |  |

| | | | | |
|----------------|---|---|--|---|
| IR_0777 |  |  |  |  |
| IR_3630 |  |  |  |  |
| IR_0729 |  |  |  |  |

A. 3. Certificado de la valoración de los resultados obtenidos por expertos médicos de la Unidad Oncológica SOLCA.

SOCIEDAD DE LUCHA CONTRA EL CANCER



**UNIDAD ONCOLOGICA
SOLCA TUNGURAHUA**

Izamba - Alfredo Coloma y Enrique Sánchez
Teléfonos: 2856098 - 2452750 - Fax: 2451995



Ambato, 14 de enero del 2015

CERTIFICADO

A QUIEN INTERESE:

Por la presente, certifico que revisé los resultados obtenidos a partir de imágenes de termografía en el desarrollo de la TESIS: "SEGMENTACION Y ANALISIS DE IMÁGENES TERMOGRÁFICAS MEDIANTE DESCRIPTORES DE TEXTURA SIMPLES" realizada por la estudiante Srta.: Tatiana Marianela Mejía Bayas y considero que reflejan adecuadamente la actividad desarrollada en perspectiva de buscar nuevas herramientas que apoyen los procesos de detección temprana de la patología mamaria aspecto de trascendencia para el quehacer institucional.

Es todo cuanto puedo certificar, pudiendo la interesada hacer uso del presente donde a bien tuviere.

Atentamente,

Dra. M.Sc. Aida Aguilar S.
CI 1801241389
Medica Tratante
SOLCA TUNGURAHUA



Anexo B: Manual de usuario del programa desarrollado

Programa para la segmentación y análisis de imágenes termográficas mediante descriptores de textura simples

En el manual se presenta una ayuda para facilitar la segmentación, análisis, clasificación de las imágenes termográficas y la evaluación del clasificador implementado, además el programa requiere para su ejecución de las siguientes imágenes que son la imagen original, ROI completo, mama izquierda y mama derecha.

Interfaz del programa

En la ventana de comandos del software Matlab se debe escribir Inicio1(), para ejecutar la aplicación que se indica en la Fig. B1, se observa la interfaz principal del programa desarrollado. La funcionalidad de cada uno de sus botones se describe a continuación:



Fig. B.1 Interfaz gráfica del programa desarrollado.

- **Salir:** Este botón pregunta si desea salir del programa, como se indica en la Fig. B.2.



Fig. B.2. Opción botón Salir.

- **Pre-procesamiento:** Este botón despliega la pantalla de la Fig. B.3, en el cual se visualiza la interfaz para el procesamiento de la imagen termográfica, a continuación se describe el funcionamiento de cada botón




Fig. B.3. Interfaz del procesamiento de la imagen termográfica

- **Imágenes:** En la esquina superior izquierda se tiene la opción Imágenes, en el cual se despliega un menú con dos opciones, Original y ROI, en la última opción se tiene ROI completo, Mama Izquierda, Mama Derecha, para abrir la galería de imágenes que se encuentra en distintas carpetas, como se observa en la Fig. B.4, las mismas que se utilizan para la demostración del programa, el tamaño de las imágenes termográficas son de 320x240 (filas, columnas), en este caso se debe abrir cada una de las imágenes mencionadas anteriormente

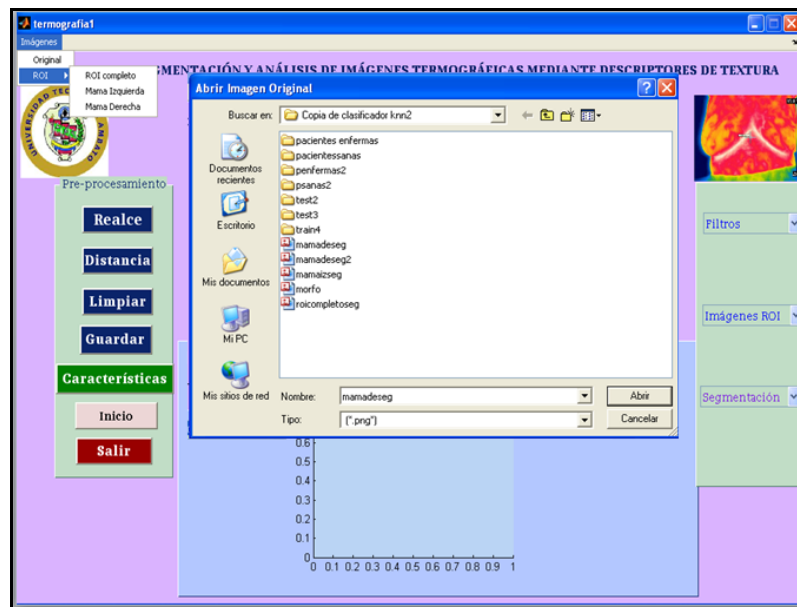


Fig. B.4. Menú Imágenes

- **Imágenes ROI:** Se visualiza una lista en forma secuencial las imágenes ROI, que se abrieron anteriormente, se debe seleccionar cada una de ellas, al seleccionar las el título sobre la imagen cambia de color. En la Fig. B.5 se observa la selección de la imagen ROI completo.

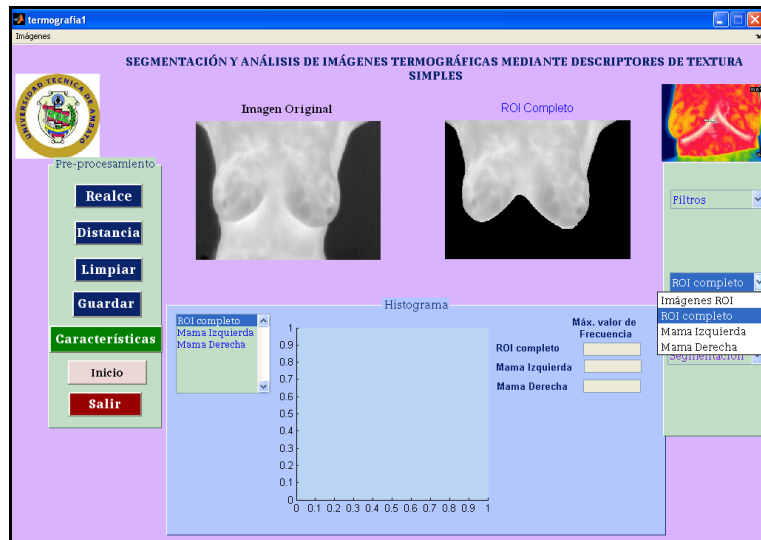


Fig. B.5. Menú Imágenes

- **Realce:** Este botón permite mejorar el contraste de la imagen termográfica, para su correcto funcionamiento se debe cargar las dos imágenes que son Original y ROI (ROI completo, mama izquierda o mama derecha), después de realizar el realce se procede con la utilización de filtros, en caso de ser necesario, en la Fig. B.6 se indica el realce de la imágenes.

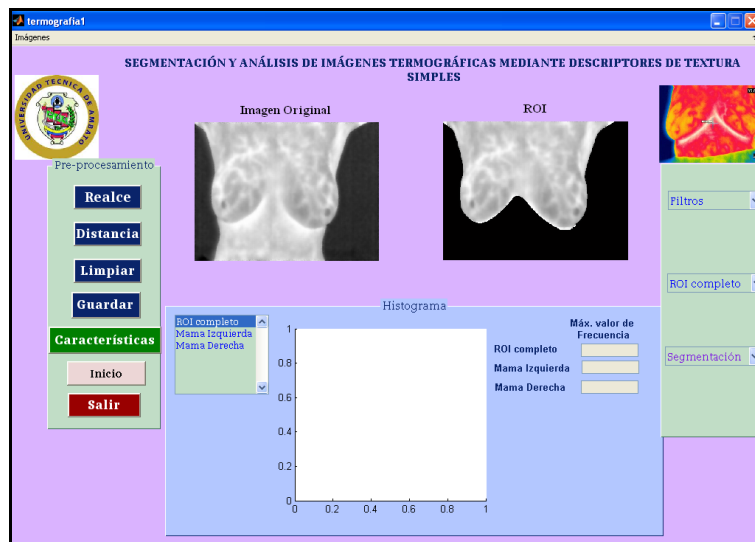


Fig. B.6. Botón Realce

- **Filtros:** Se visualiza una lista de opciones con los diferentes filtros, los cuales permiten mejorar la imagen y se detallan a continuación:

Simétrico.- Filtro de suavizado espacial, para mejorar la nitidez de la imagen (Fig. B.7)

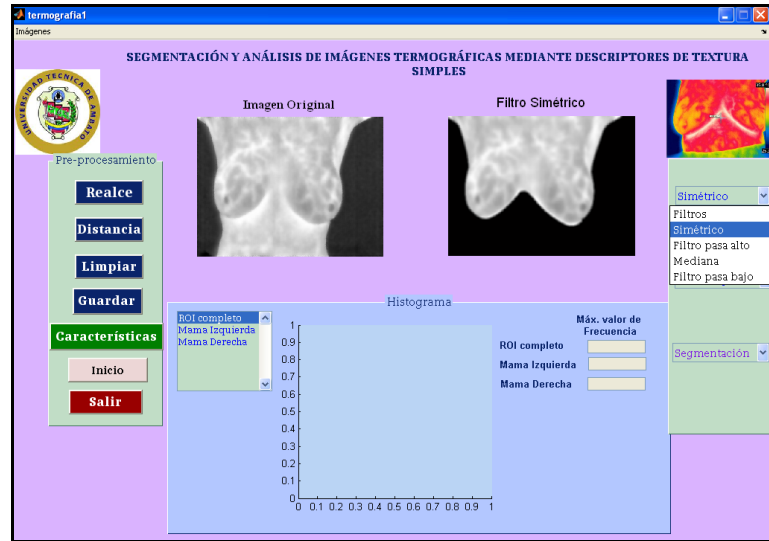


Fig. B.7. Filtro Simétrico

Filtro pasa alto.- Resalta los bordes y el contraste de la imagen, en la Fig. B.8 se aplica un filtro pasa alto a la imagen después de aplicar un realce.

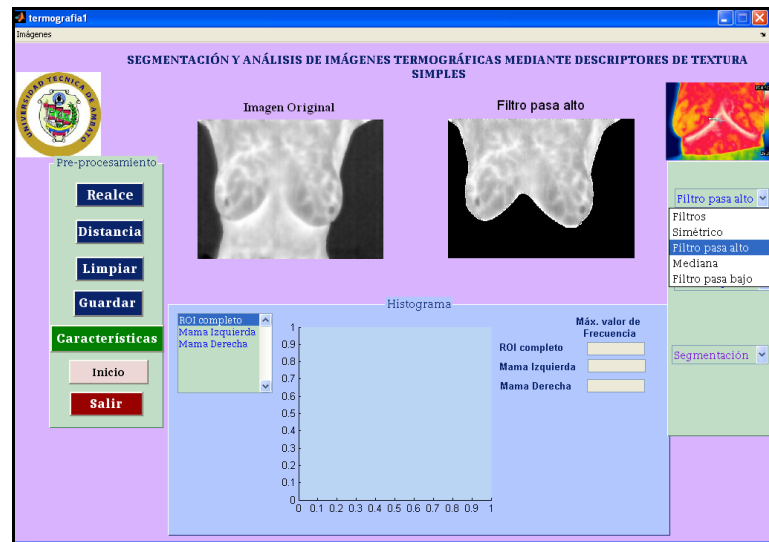


Fig. B.8. Filtro pasa alto

Mediana.- Utilizado para reducir el ruido y al mismo tiempo preservar los bordes, los resultados al aplicar este filtro se visualiza en la Fig. B.9

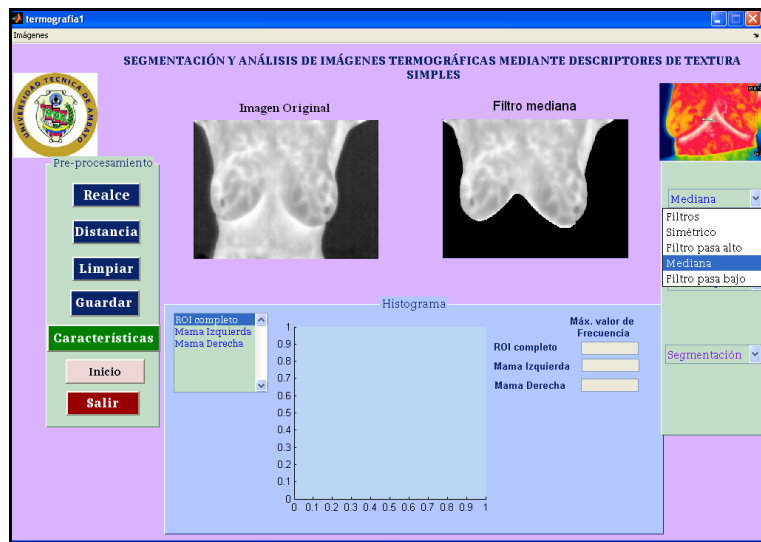


Fig. B.9. Filtro mediana

Filtro pasa bajo.- Suaviza y elimina el ruido que tiene la imagen, en la Fig. B.10 se observa un ejemplo de filtro pasa bajo

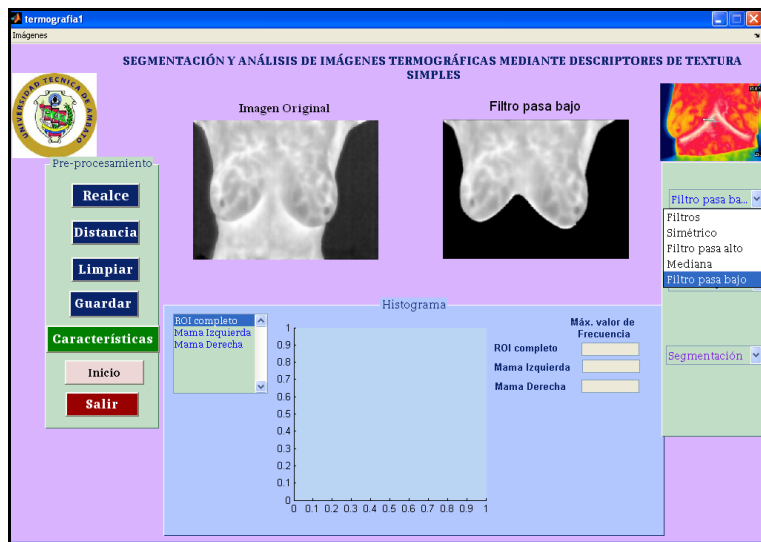


Fig. B.10. Filtro mediana

➤ **Segmentación.-** Se despliega una lista de opciones, las cuales segmentan la región de interés, a continuación se detallan las opciones:

Gradiente.- Utilizado para detectar los bordes de la imagen, como se indica en la Fig. B.11

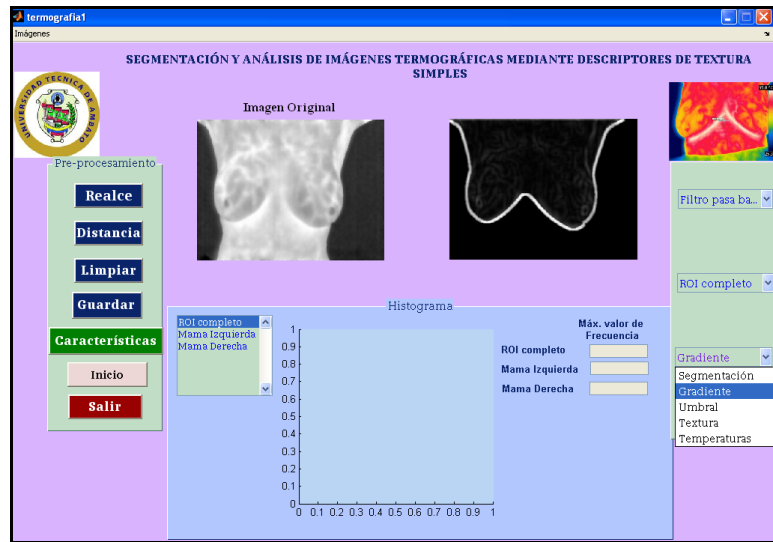


Fig. B.11. Gradiente

Umbral.- Se realiza mediante un umbral de 0.73, mediante este umbral se visualiza la región de interés, como se indica en la Fig. B.12

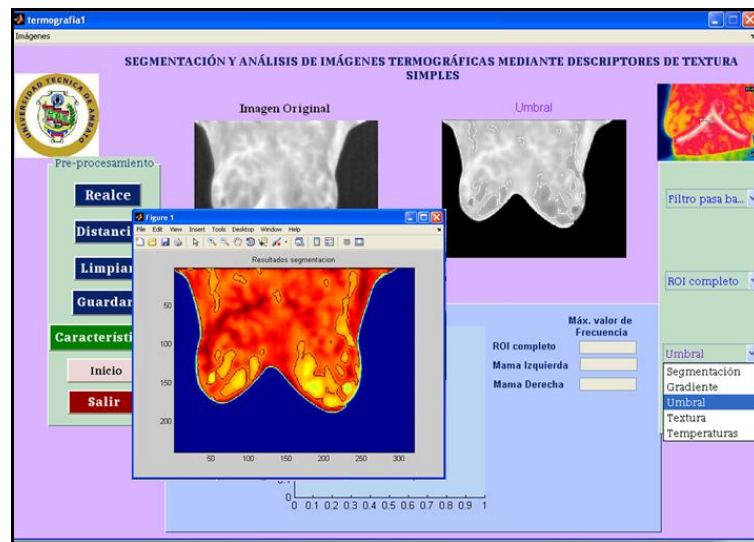


Fig. B.12. Segmentación por umbral=0.73

Textura.- Se visualiza la textura de la imagen, como se observa en la Fig. B.13.

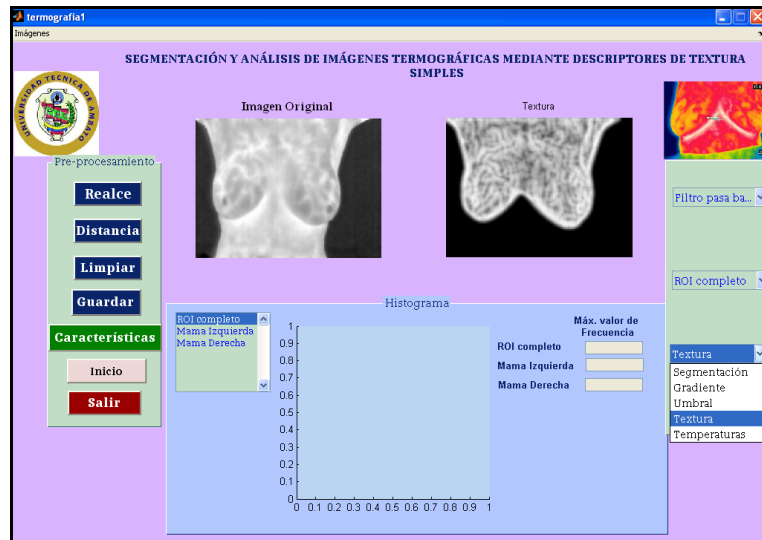


Fig. B.13. Textura de la imagen

Temperaturas.- La segmentación se realiza al agrupar los píxeles con mayor intensidad encontrados en la imagen, como se indica en la Fig. B.14

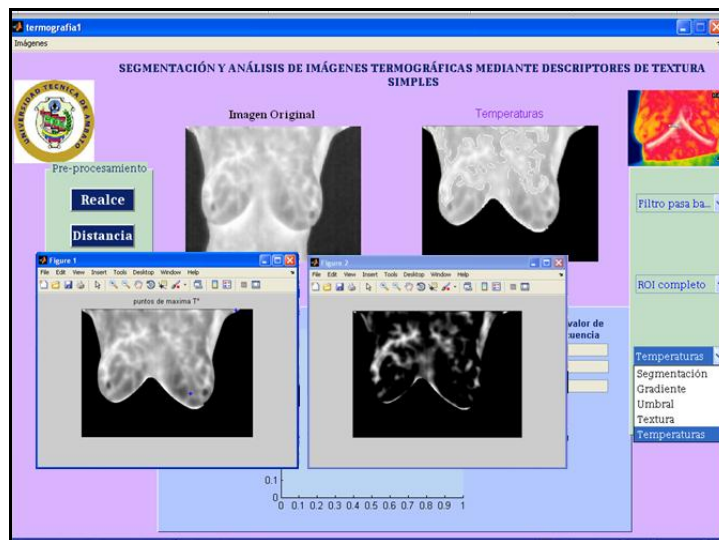


Fig. B.14. Máximas Temperaturas

➤ **Distancia.-** Se logrará obtener el tamaño de una sección determinada de la imagen, en la Fig. B.15 se muestra un ejemplo.

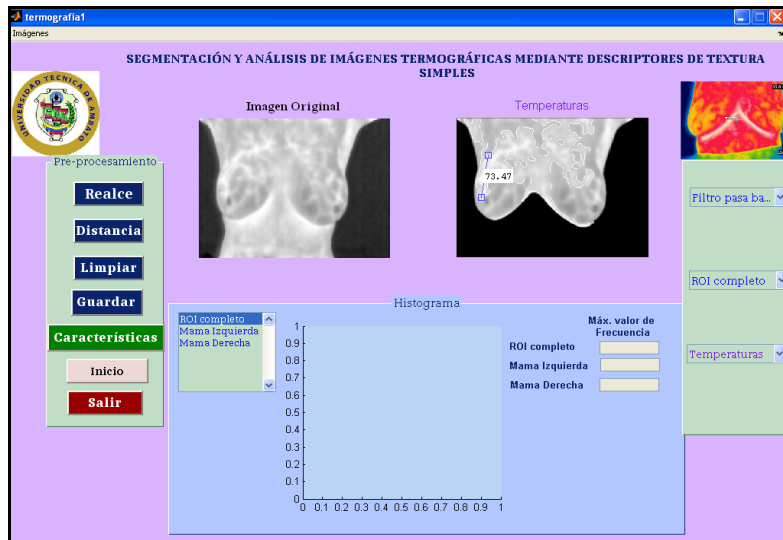


Fig. B.15. Botón distancia

- **Guardar.-** Permite guardar la imagen segmentada, la cual se almacena por defecto en la carpeta de Matlab con el nombre que se le asigne, como se indica en la Fig. B.16.

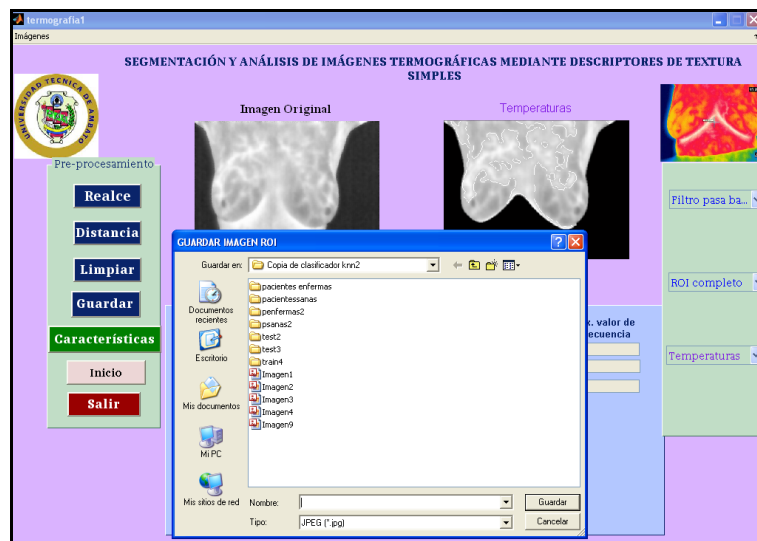


Fig. B.16. Guardar Imagen

- **Histograma.-** Se visualiza en una lista las imágenes: ROI completo, mama izquierda y mama derecha, al seleccionar cada una de ellas se visualiza su correspondiente histograma, además de indicar el máximo valor de frecuencia del

mismo para cada caso, en la Fig. B.17 se indica el histograma de la imagen ROI completo.

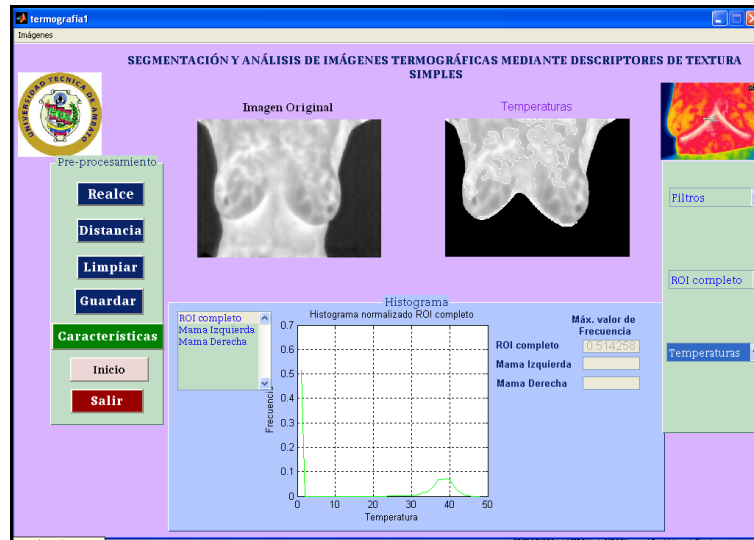


Fig. B.17. Histograma ROI completo

Además de los botones explicados anteriormente, se crearon tres botones adicionales, un botón para limpiar el área de trabajo, otro para volver al inicio, para salir del programa, así también un botón para abrir la interfaz de características, la interfaz mencionada anteriormente se indica en la Fig. B.18

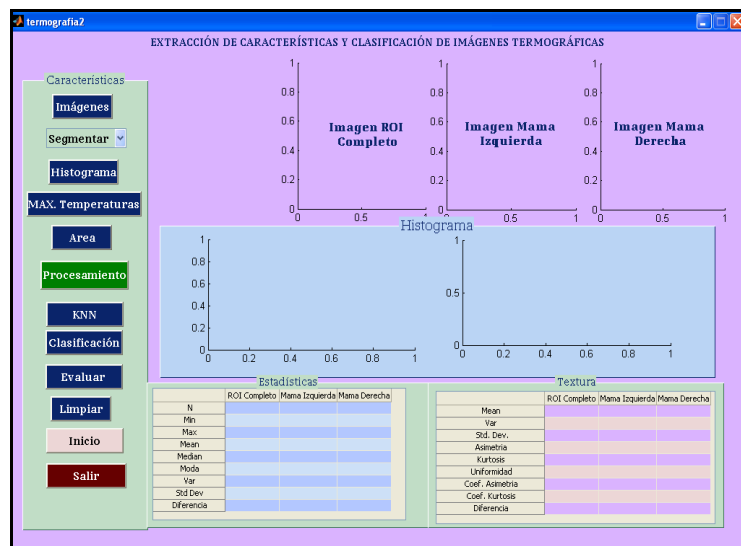


Fig. B.18. Interfaz gráfica de características

Imágenes.- Al presionar este botón se visualiza las tres imágenes: ROI completo. Mama izquierda mama derecha, previamente se ha realizado un realce.

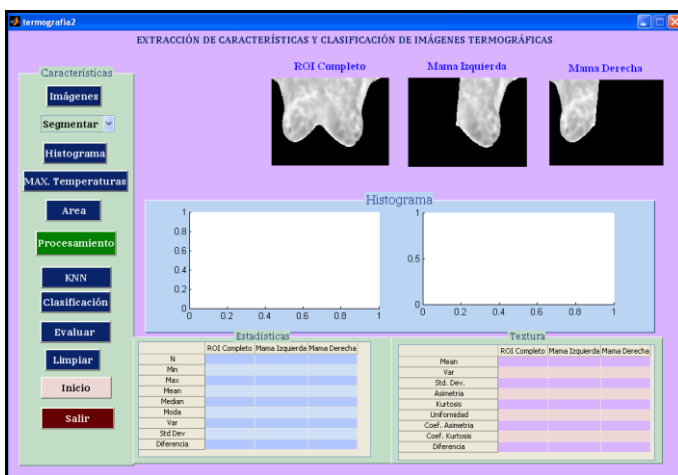


Fig. B.19. Interfaz gráfica de características

De manera similar, se ha creado una lista en la cual se despliega dos formas de segmentar la imagen: por umbral, además de máximos y mínimos regionales (máximas temperaturas), también se crea botones para obtener el histograma de la imagen segmentada, de la imagen original se encuentra las máximas temperaturas, se puede limpiar el área de trabajo, así también encontrar el área de la imagen segmentada, adicionalmente los botones para salir, para volver al inicio o al procesamiento, en la Fig. B.20 se indica lo explicado anteriormente.

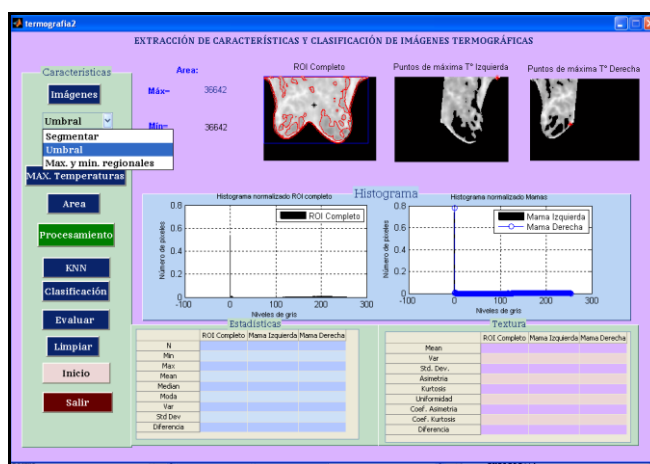


Fig. B.20. Interfaz gráfica de características

KNN.- Permite obtener el resultado de la imagen como anormal o normal, en la Fig. B.21, se indica la clasificación de la imagen IR_7464, anormal, los parámetros de estadística y textura se obtienen al seleccionar de la cada una de las tablas, ROI completo, Mama Izquierda, Mama Derecha, al presionar el botón clasificación se visualiza la diferencia entre mamas para cada caso, además de indicar si es anormal o normal.

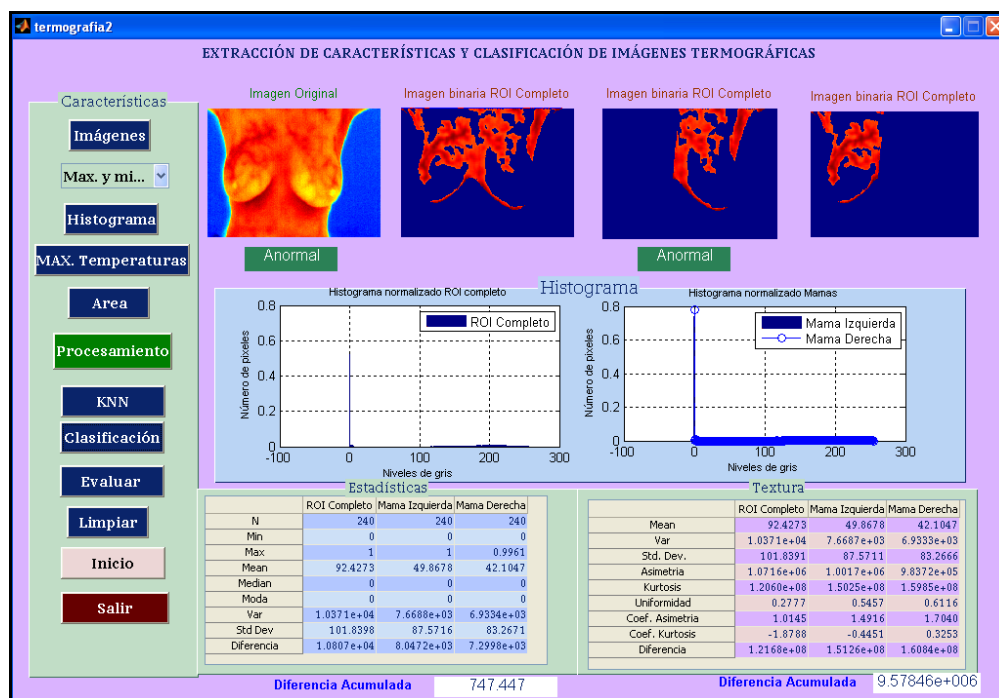


Fig. B.21. Clasificación de la Imagen

Evaluar.- Se evalúa al clasificador, mediante la creación de una carpeta de entrenamiento, que contiene 9 imágenes anormales y 9 normales, de igual manera una carpeta de test con igual número de imágenes explicadas anteriormente, en la Fig. B.22 se visualiza los valores obtenidos.

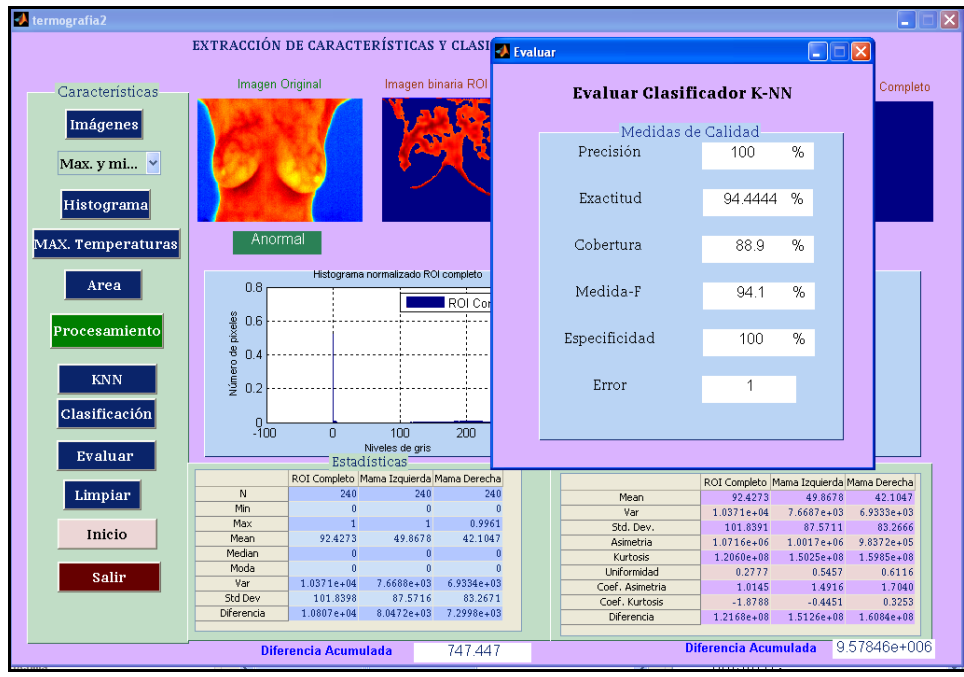


Fig. B.22. Evaluación del clasificador