



BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA

FACULTAD DE CIENCIAS DE LA COMPUTACIÓN

PROCESAMIENTO Y ANÁLISIS DE IMÁGENES
TÉRMICAS PARA DOMINIOS MÉDICOS

TESIS

PRESENTADA PARA OBTENER EL TÍTULO DE:

Maestría en Ciencias de la Computación

PRESENTA:

Daniel Sánchez Ruiz

DIRECTORES DE TESIS:

Dr. José Luis Carballido Carranza

Dr. Ivan Olmos Pineda

Puebla, Puebla, México

Septiembre 2018



Agradecimientos

A mis directores de tesis, los Dres. Ivan Olmos Pineda y José Luis Carballido Carranza, por su apoyo en todo momento y sus valiosos comentarios.

A los Dres. José Arturo Olvera López y Mario Rossainz por sus comentarios y todos los consejos que me dieron en la elaboración de este proyecto.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico que me permitió estudiar la Maestría.

A la Facultad de Ciencias de la Computación perteneciente a la Benemérita Universidad Autónoma de Puebla que me dió la oportunidad de realizar los estudios de posgrado y así cumplir una de mis metas en la vida.

Finalmente a mi familia y mi pareja, sin su apoyo y amor no habría podido lograr este sueño.

Índice general

| | |
|---|----------|
| Agradecimientos | III |
| Lista de Figuras | VII |
| Lista de Tablas | X |
| 1. Introducción | 1 |
| 1.1. Antecedentes | 1 |
| 1.2. Planteamiento del Problema | 2 |
| 1.3. Objetivos Generales y Específicos del Proyecto | 3 |
| 1.3.1. Objetivo General | 3 |
| 1.3.2. Objetivos específicos | 3 |
| 1.4. Hipótesis | 3 |
| 1.5. Justificación | 3 |
| 1.6. Estructura | 3 |
| 2. Marco Teórico | 5 |
| 2.1. Termografía | 5 |
| 2.1.1. Termografía | 5 |
| 2.1.2. Cámaras Térmicas | 7 |
| 2.1.3. Imágenes térmicas en ámbitos médicos | 8 |
| 2.2. Procesamiento de Imágenes Digitales | 10 |
| 2.2.1. Imagen Digital | 10 |
| 2.2.2. Histograma | 11 |
| 2.2.3. Método de umbralización Otsu | 12 |
| 2.2.4. Mejora de Contraste Acumulativo | 13 |
| 2.2.5. Segmentación | 15 |
| 2.2.6. Interpolación de Lagrange | 16 |
| 2.2.7. Extracción de Características | 17 |
| 2.2.8. Características de Primer Orden | 17 |
| 2.2.9. Características de Segundo Orden | 19 |
| 2.3. Aprendizaje Automático | 21 |
| 2.3.1. Aprendizaje supervisado | 22 |
| 2.3.2. Redes Neuronales Artificiales | 22 |

| | | |
|-----------|---|-----------|
| 2.3.3. | Normalización de atributos | 25 |
| 2.3.4. | Selección de Características | 26 |
| 2.3.5. | Validación Cruzada | 26 |
| 2.3.6. | Métricas de validación | 27 |
| 3. | Estado del Arte | 31 |
| 3.1. | Trabajo relacionado | 31 |
| 3.2. | Análisis de Trabajos | 35 |
| 4. | Metodología | 37 |
| 4.1. | Adquisición de imágenes | 37 |
| 4.2. | Selección de imágenes | 38 |
| 4.2.1. | Depuración de base de datos | 39 |
| 4.2.2. | Imágenes a ocupar | 39 |
| 4.3. | Pre-procesamiento de imágenes | 40 |
| 4.3.1. | Conversión a Escala de Grises | 40 |
| 4.3.2. | Segmentación de fondo | 41 |
| 4.4. | Segmentación de ROI | 42 |
| 4.4.1. | Identificación de límite inferior de la ROI | 42 |
| 4.4.2. | Identificación de límite superior de la ROI | 45 |
| 4.4.3. | Segmentación de la ROI | 47 |
| 4.5. | Extracción de Características | 47 |
| 4.5.1. | Características de Primer Orden | 48 |
| 4.5.2. | Características de Segundo Orden | 48 |
| 4.5.3. | Vectores de Características generados | 49 |
| 4.6. | Balanceo de la base de datos | 49 |
| 4.7. | Clasificación de Imágenes ocupando una Red Neuronal | 50 |
| 4.7.1. | Normalización de atributos | 50 |
| 4.7.2. | Selección de Características | 50 |
| 4.7.3. | Búsqueda mejores hiperparámetros | 51 |
| 4.7.4. | Validación | 51 |
| 4.8. | Diagrama general de la Metodología | 51 |
| 5. | Resultados | 53 |
| 5.1. | Resultados Segmentación | 53 |
| 5.2. | Experimentos de Reconocimiento de Patrones | 54 |
| 5.2.1. | Balanceo de base de datos | 55 |
| 5.2.2. | Resultados sin búsqueda de mejores hipermetros | 56 |
| 5.2.3. | Búsqueda de hiperparámetros | 62 |
| 5.2.4. | Resultados con uso de hiperparámetros encontrados | 64 |
| 5.2.5. | Vector-1 | 64 |
| 5.2.6. | Vector-5 | 66 |
| 5.3. | Discusión | 67 |

| | |
|---|-----------|
| 6. Conclusiones y Trabajo Futuro | 71 |
| 6.1. Trabajo Futuro | 72 |
| A. Publicaciones | 73 |

Índice de figuras

| | |
|---|----|
| 2.1. Ejemplos de imágenes térmicas | 7 |
| 2.2. Cámara térmica | 8 |
| 2.3. Representación de una imagen digital | 10 |
| 2.4. Histograma de una imagen | 11 |
| 2.5. Operación de auto contraste | 14 |
| 2.6. Ejemplos con intepolación de Lagrange | 17 |
| 2.7. Ejemplo de creación de GLMC | 20 |
| 2.8. Diagrama de una Red Neuronal | 23 |
| 2.9. Red de una capa con una salida y dos entradasl | 24 |
| 2.10. Ejemplo de validación cruzada | 27 |
| 4.1. Ejemplos de imágenes de la base de datos | 38 |
| 4.2. Ejemplos de distintas clases de imágenes | 39 |
| 4.3. Ejemplo de imágenes deficientes | 40 |
| 4.4. Descomposición en cada canal de imagen RGB | 41 |
| 4.5. Histograma de imagen mostrando valle entre valores | 42 |
| 4.6. Resultado de segmentación de fondo | 42 |
| 4.7. Imagen dividida en sub regiones y sub imágenes seleccionadas | 43 |
| 4.8. Proceso de mejora de contraste de sub imagen | 44 |
| 4.9. Proceso de mejora de contraste de sub imagen segmentada | 44 |
| 4.10. Imagen binarizada con umbral encontrado automáticamente | 45 |
| 4.11. Imagen después de aplicar análisis por densidad de regiones | 45 |
| 4.12. Límite inferior definido así como punto de intersección | 46 |
| 4.13. Identificación de límite superior de ROI | 46 |
| 4.14. Resultados del método de segmentación automática de la ROI | 47 |
| 4.15. Diagrama general de la metodología | 52 |
| 5.1. Resultado obtenido con método de segmentación automática | 54 |
| 5.2. Categorías de Resultados de ROI | 54 |
| 5.3. Resultados de segmentación automática y segmentación manual | 55 |
| 5.4. Matrices obtenidas en cada experimento con vector 1 | 57 |
| 5.5. Matrices obtenidas en cada experimento con vector 2 | 58 |
| 5.6. Matrices obtenidas en cada experimento con vector 3 | 58 |
| 5.7. Matrices obtenidas en cada experimento con vector 4 | 59 |
| 5.8. Matrices obtenidas en cada experimento con vector 5 | 60 |
| 5.9. Matrices obtenidas en cada experimento con vector 6 | 60 |
| 5.10. Matrices obtenidas en cada experimento con vector 7 | 61 |
| 5.11. Evaluación de distintos valores para todos los parámetros con el vector 1 | 63 |
| 5.12. Evaluación de distintos valores para todos los parámetros con el vector 5 | 63 |

Índice de figuras

| | |
|---|----|
| 5.13. Comportamiento de las métricas de evaluación a lo largo de los experimentos para vector 1 y ajuste de hiperparámetros | 65 |
| 5.14. Matrices obtenidas en cada experimento con vector 1 y ajuste de hiperparámetros | 65 |
| 5.15. Comportamiento de las métricas de evaluación a lo largo de los experimentos para vector 5 y ajuste de hiperparámetros | 66 |
| 5.16. Matrices obtenidas en cada experimento con vector 5 y ajuste de hiperparámetros | 67 |

Índice de cuadros

| | |
|---|----|
| 2.1. Modalidades de imágenes para la detección de Cáncer de Mama | 9 |
| 2.2. Características ideales para el método de detección temprana de cáncer de mama | 9 |
| 2.3. Tipos de imágenes con base en su profundidad de bits | 11 |
| 2.4. Combinaciones de GLMC | 20 |
| 2.5. Matriz de Confusión para tuplas negativas y positivas | 28 |
| 3.1. Análisis de las características extraídas de la región de interés | 36 |
| 4.1. Resumen de depuración de registros | 40 |
| 4.2. Vectores de Características propuestos | 49 |
| 4.3. Distribución de clases de imágenes en base de datos | 50 |
| 5.1. Rendimiento de método segmentación automática en base de datos | 53 |
| 5.2. Resument por categoria de segmentación | 54 |
| 5.3. Resumen de instancias a ocupar en experimentos | 55 |
| 5.4. Lista de hiperparámetros y sus valores fijos de Red Neuronal | 56 |
| 5.5. Resultados de reconocimiento de patrones con vector 1 | 56 |
| 5.6. Resultados de reconocimiento de patrones con vector 2 | 57 |
| 5.7. Resultados de reconocimiento de patrones con vector 3 | 58 |
| 5.8. Resultados de reconocimiento de patrones con vector 4 | 59 |
| 5.9. Resultados de reconocimiento de patrones con vector 5 | 59 |
| 5.10. Resultados de reconocimiento de patrones con vector 6 | 60 |
| 5.11. Resultados de reconocimiento de patrones con vector 7 | 61 |
| 5.12. Rango de valores para hiperparámetros | 62 |
| 5.13. Hiperparámetros a ocupar | 62 |
| 5.14. Resultados de reconocimiento de patrones con vector 1 | 64 |
| 5.15. Resultados de reconocimiento de patrones con vector 5 con ajuste de hiperparámetros | 66 |
| 5.16. Estudios similares en la detección de anormalidades en imágenes termográficas de pechos | 69 |

1 Introducción

Este capítulo presenta una introducción acerca de los temas que abordará esta investigación, empezando por los antecedentes del uso de imágenes digitales en ámbitos médicos, detalles de forma breve sobre el procesamiento y análisis de estas imágenes, haciendo el planteamiento del problema, definiendo los objetivos generales y particulares partiendo de la hipótesis de la investigación, también se da una justificación de por qué sería relevante esta investigación. Finalmente se detalla la estructura del resto del documento.

1.1. Antecedentes

En el área del procesamiento y análisis de imágenes existe una etapa referente a la extracción de características. Estas características son útiles para entrenar un clasificador con base en patrones que se identifiquen de características extraídas, todo esto respecto a las clases que se quiera diferenciar en las imágenes. Es por ello que este tema es de particular interés en las investigaciones actuales pues una correcta elección de las características brinda mejores resultados en la etapa de la clasificación. En esta tesis las imágenes con las que se trabaja son del tipo térmicas. Una imagen térmica captura cualquier radiación de la banda infrarroja de cualquier objeto. El uso de las imágenes térmicas ha tenido distintas aplicaciones, desde aplicaciones en el sector industrial, sistemas de vigilancia hasta sistemas médicos. En este trabajo se presenta una metodología para la extracción de características en imágenes térmicas en un ámbito médico, en particular para poder realizar una detección de anomalías en mamas con base en un modelo de clasificación.

Las imágenes digitales han sido de mucha ayuda en el ámbito médico, ya que existen infinidad de estudios como los rayos X, tomografías o ultrasonidos entre otros, que generan imágenes que ayudan en la decisión de emitir un diagnóstico por parte de los especialistas. El dominio en concreto dentro del ámbito médico que se estudiara es el de cáncer de mama. Existen muchas pruebas y exámenes para poder diagnosticar el cáncer de mama, desde mamogramas, rayos X de pecho hasta ultrasonidos entre otros, que si bien son efectivos son caros o muy invasivos.

Otra herramienta que se ocupa cada vez más para un diagnóstico más exacto es el de

analizar imágenes térmicas del área de interés, esto con el propósito de identificar anomalías. Las imágenes térmicas se empezaron a ocupar en la década de 1960 [23, 31]. Sin embargo la sensibilidad de los dispositivos no era la mejor. En años recientes se ha visto afectado de forma considerable el costo de estos dispositivos, teniendo una tendencia hacia la baja, así como en su calidad, subiendo su eficiencia y exactitud en sus mediciones. Además estos dispositivos se han elaborado cada vez más con componentes de menor tamaño favoreciendo su transporte de punto a punto.

Con estos avances en años recientes el análisis de imágenes térmicas para la detección de anomalías de mama ha tenido un nuevo auge, convirtiéndose en un método que cada vez es más fiable y ocupado por instituciones médicas.

Es por ello que este tipo de desarrollo tecnológico brinda un avance económico, social y médico. Ya que es una forma menos invasiva de realizar un examen al evitar emitir radiaciones nocivas para cualquier individuo, así como de ocupar equipos que tienen la característica de ser portátiles. Además para realizar un examen solo se requiere de una cámara térmica así como una base de datos de exámenes previos que se hayan realizado que sirvan de punto de referencia.

Cabe aclarar que esta tecnología no es excluyente de los otros métodos para detectar anomalías, pues se sabe que el único método capaz de detectar al 100 % el cáncer es la biopsia, los demás estudios, como el presente, únicamente encuentran de distintas formas anomalías y de encontrar alguna el especialista hará más estudios a profundidad para encontrar la causa [11, 43].

1.2. Planteamiento del Problema

Los estudios basados en termografías para la detección de alguna anomalía en las mamas aún está en proceso de aceptación y validación, de tal modo que en la actualidad aquellos especialistas que llegan a hacer uso de alguno de estos sistemas tienen problemas que enfrentar, bien sea un cierto desconocimiento de la tecnología empleada, la falta de claridad en la interpretación de los resultados o la estandarización de un método para la captura de las imágenes, sólo por mencionar algunos.

Además es el especialista el que interpreta los datos obtenidos por la cámara de infrarrojos y junto con el historial clínico que tiene de la paciente emite, a su juicio, un pre-diagnóstico. Los datos que obtiene el especialista, no han sido procesados para la extracción de características representativas a nivel estadístico, más bien son analizados únicamente de forma visual, lo cual puede conllevar a un mal pre-diagnóstico. Además que el prediagnóstico puede estar altamente sesgado por el criterio del especialista y no por un método estándar para todos los pacientes.

Ante todo lo descrito es que el presente trabajo busca automatizar el proceso de análisis de estudios termográficos con el fin de apoyar a los especialistas a emitir un pre-diagnóstico

Capítulo 1. Introducción

más certero. Para ello se hace uso de técnicas estadísticas que permitan clasificar los datos que posea el experto en casos positivos como en casos negativos.

1.3. Objetivos Generales y Específicos del Proyecto

1.3.1. Objetivo General

Diseñar una metodología para extraer características en imágenes térmicas utilizando distintas técnicas de análisis estadístico para la detección de anomalías en mamas.

1.3.2. Objetivos específicos

- Crear cuadro comparativo de las diferentes características extraídas en trabajos relacionados
- Crear o bien obtener (de un repositorio público) una base de imágenes térmicas para la detección de anomalías en mamas
- Seleccionar características descriptivas en imágenes térmicas que ocupen un conjunto de operadores matemáticos
- Implementar la propuesta para la extracción de características en imágenes térmicas
- Determinar cuantitativamente la calidad de las características extraídas

1.4. Hipótesis

La información que proporcionan las imágenes térmicas provee un conjunto de características que permiten clasificarlas adecuadamente en tareas de aprendizaje automático

1.5. Justificación

Si bien en los últimos tiempos ha ido en aumento el trabajo en este tema, aún existe un escaso trabajo en aplicación de técnicas de clasificación sobre los datos obtenidos de la termografía y la forma en que realiza el pre-diagnóstico el especialista. Esto se debe a que a pesar de los avances en la tecnología para la captura de estas imágenes, las bases de datos son complejas de clasificar debido a que el número de atributos es grande y a la posible presencia de ruido, atributos discretos y numéricos combinados, y posibles valores incompletos.

Por otro lado es pertinente como se mencionó en el planteamiento aportar en el desarrollo de estos métodos para su pronta aceptación, pues sin duda es una herramienta que los especialistas pueden agregar en sus análisis.

1.6. Estructura

El documento está estructurado de la siguiente forma en los siguientes capítulos:

- **Capítulo 2. Marco Teórico.** Se presentan definiciones y conceptos necesarios para poder comprender la investigación.
- **Capítulo 3. Estado del Arte.** Se realiza un estudio y análisis de los trabajos relacionados a la investigación para poder ubicar la contribución del presente trabajo.
- **Capítulo 4. Metodología.** Se describe el conjunto de datos a utilizar para la aplicación de la metodología que se propone. También se describe en detalle los pasos de cada una de las fases que comprenden a la metodología.
- **Capítulo 5. Resultados** Se muestran los resultados de los experimentos realizados con el propósito de medir su efectividad y además se analizan y describen los resultados obtenidos.
- **Capítulo 6. Conclusiones** Se presentan las conclusiones del trabajo realizado y el trabajo futuro a realizar.

2 Marco Teórico

Este capítulo define algunos conceptos básicos para entender completamente esta investigación. Entre ellos se describe la termografía, la captura de imágenes térmicas a través de cámaras especializadas, el uso de la termografía en ámbitos médicos. Por otro lado se definen conceptos básicos para el procesamiento de imágenes digitales referentes a las partes del pre-procesamiento, segmentación de la región de interés y la extracción de características. Finalmente se dan conceptos relacionados al aprendizaje automático.

2.1. Termografía

Para poder comprender el funcionamiento de la termografía en una forma técnica, esta sección describe cómo funciona la termografía, la cámara termográfica como dispositivo de adquisición de imágenes y sus características y antecedentes sobre el uso de imágenes térmicas en un ámbito médico.

2.1.1. Termografía

La termografía infrarroja (IR), también llamada brevemente termografía, es un campo que ha evolucionado rápidamente en la ciencia así como en la industria debido al enorme progreso realizado en las últimas dos décadas en el diseño, hardware y software en microsistemas de detección IR. La termografía hoy en día se aplica en investigación y desarrollo, así como en una variedad de diferentes campos en la industria como pruebas no destructivas, monitoreo de condiciones y mantenimiento predictivo, reduciendo los costos de energía de procesos y edificios, detección de especies gaseosas, y muchos más [62]. Otras de las aplicaciones más importantes se listan a continuación [41]:.

- **Imágenes aéreas.** Detección de incendios forestales, Inspección de líneas eléctricas, Inspección de paneles solares, Búsqueda y rescate de personas
- **Agricultura.** Administración de dispositivos de irrigación, adquisición de información

acerca del congelamiento en las plantas, etc.

- **Asfalto.** Detección de defectos de forma preventiva en pavimento
- **Electricidad.** Monitoreo rural y urbano de líneas de electricidad
- **Ambiental.** Vigilancia ininterrumpida de comportamiento animal, investigación en cambio climático a través de medición de cambios de temperatura en el ambiente
- **Techos de construcciones.** Inspecciones de estructuras y cableado en edificaciones
- **Animales.** Ubicación y conteo de animales en granjas industriales
- **Herencia Cultural.** Control del estado de conservación de obras de arte, frescos y pinturas
- **Médica.** Diagnóstico de melanoma, hipertermia, inflamación muscular, cáncer de mama, etc.
- **Investigación química.** Monitoreo de nivel de líquidos, pruebas para comprobar el aislamiento o fugas en reactores
- **Industria automotriz.** Análisis de calidad durante la producción de todos los componentes internos
- **Metalurgia.** Reducción de forma eficiente del consumo de energía en procesos metalúrgicos utilizando sistemas de cámara infrarroja
- **Milicia.** Identificación de objetivos y personas en condiciones de poca iluminación

La termografía es un excelente ejemplo de una técnica de visualización que se puede utilizar en muchos campos diferentes de la física y la ciencia. Además, ha abierto un nuevo campo de la física en términos de visualización. Hoy en día, es posible visualizar fácilmente los efectos invisibles (para el ojo humano) del aumento de la temperatura del suelo al impacto de un objeto que cae o al interactuar con el zapato de una persona que camina [62]. Esta técnica determina la radiación infrarroja de un objeto bajo estudio. Convierte la energía radiada en señales eléctricas que son amplificadas y traducidas en imágenes, unos ejemplos de imágenes térmica se muestra en la Figura 2.1.

El proceso de la termografía involucra una serie de conversiones, a continuación se explica cómo funciona [61]:

- Una lente especial enfoca la luz infrarroja emitida por todos los objetos a la vista.

- La luz enfocada se escanea con un detector de infrarrojos. Los elementos del detector crean un patrón de temperatura muy detallado llamado termograma. Toma alrededor de un trigésimo de segundo hacer el termograma.

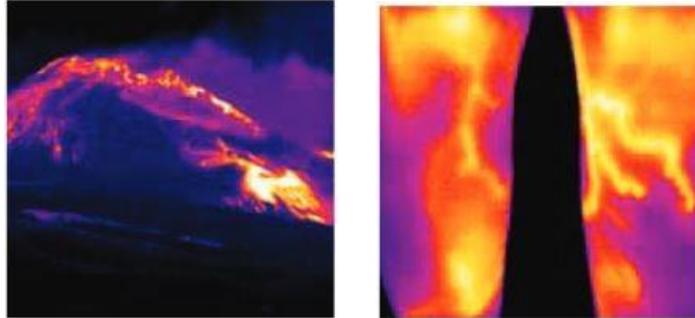


Figura 2.1 – Ejemplos de imágenes térmicas

- El termograma creado se traduce en impulsos eléctricos.
- Los impulsos se envían a una unidad de procesamiento de señal, que traduce la información de los elementos en datos para la pantalla.
- La combinación de todos los impulsos de todos los elementos crea la imagen.

2.1.2. Cámaras Térmicas

Una cámara térmica es un dispositivo que detecta la energía infrarroja (calor) sin necesidad de contacto y convierte el calor detectado en una señal electrónica. Luego, la señal electrónica se procesa para producir un termograma (imagen térmica), que muestra los valores de temperatura de los objetos fotografiados. Este dispositivo ayuda a controlar el rendimiento térmico o los problemas relacionados con el calor en el objeto estudiado [4]. Los elementos de una cámara infrarroja son los siguientes: Objetivos, Sensores, Batería, Monitor y Almacenamiento de memoria.

Los elementos más importantes son los objetivos y los sensores. Los objetivos son el sistema óptico que incorpora varias lentes individuales. Esas lentes definen el campo de visión de la cámara, este sistema permite obtener la cantidad adecuada de IR para el sensor. Las distancias de enfoque mínimas entre 0.3m y 0.5m en cámaras portátiles comerciales [6]. El sensor que detecta IR es la matriz de plano focal (FPA), que es un circuito integrado hecho de antimonio de indio (InSb) y arseniuro de indio y galio (InGaAs); este componente de la cámara convierte la radiación térmica en señales eléctricas, que luego se procesan para crear una imagen [5]. El modelo que se ocupó en las imágenes de esta investigación se muestra en la Figura 2.2. La cámara térmica tiene las siguientes características [3]:

- Resolución de 640 x 480 pixeles

- Rango de temperatura de -40°C a $+500^{\circ}\text{C}$
- Sensibilidad térmica de 40 mK a 30°C
- Captura de matrices de temperatura asociadas a la imagen

FLIR SC620



Figura 2.2 – Cámara térmica

2.1.3. Imágenes térmicas en ámbitos médicos

Las imágenes IR en medicina se han utilizado en el pasado pero sin la ventaja de la tecnología del siglo XXI. En 1994, bajo las subvenciones del Departamento de Defensa (DOD) financiadas conjuntamente por la Oficina del Secretario de Defensa, la Agencia de Proyectos de Investigación Avanzada de Defensa (DARPA) y la Oficina de Investigación del Ejército (ARO) en Estados Unidos, se inició un esfuerzo concertado para revisar este tema. Específicamente, fue para explorar el potencial de la integración de la tecnología avanzada de IR con el procesamiento de imágenes 'inteligentes' para su uso en medicina. Se investigaron los principales desafíos para la aceptación de esta modalidad por parte de la comunidad médica. Se encontró que los siguientes temas eran de primordial importancia: estandarización y cuantificación de datos clínicos, mejor comprensión de la naturaleza fisiopatológica de las firmas térmicas, publicación más amplia y exposición de imágenes IR médicas en conferencias y diarios, caracterización de firmas térmicas a través de una base de datos interactiva en la web y capacitación tanto en adquisición de imágenes como en interpretación [62].

En la actualidad, las imágenes IR se utilizan en muchas aplicaciones médicas diferentes. Los más destacados son oncología (mama, piel, etc.), trastornos vasculares (diabetes, TVP, etc.), dolor, cirugía, viabilidad tisular, control de la eficacia de medicamentos y terapias; respiratorio (recientemente introducido para las pruebas de SARS). Hay varios métodos utilizados para adquirir imágenes IR: estática, dinámica, pasiva y dinámica de área activa entre otras. Después la investigación del uso de estas imágenes se prosiguió en otros países como China, Corea, Japón, Polonia, Italia, etc. [62].

En detalle, la termografía de mama se basa en la premisa de que, antes de que sea posible el crecimiento de células anormales, debe distribuirse un suministro de sangre constante al área de crecimiento. La termografía mide la temperatura de la superficie del pecho y, por tanto, el calor generado por la microcirculación de sangre en la mama durante este proceso.

La actividad química y de los vasos sanguíneos tanto en el tejido precanceroso como en el área que rodea un cáncer de mama en desarrollo casi siempre es más alta que en el seno normal [46, 8]. Dado que las masas cancerosas son tejidos altamente metabólicos, necesitan

un suministro abundante de nutrientes para mantener su crecimiento, lo que se logra aumentando el suministro de sangre a sus células. El aumento resultante en las temperaturas

| |
|---|
| Mamografía |
| Ultrasonido |
| Detección Asistida por Computador |
| Imagen de Resonancia Magnética (MRI) |
| Tomografía de emisión de positrones (PET) |
| Termografía |
| Imagen de impedancia eléctrica |

Fuente [17]

Cuadro 2.1 – Modalidades de imágenes para la detección de Cáncer de Mama

| |
|--|
| Detecta tempranamente la lesión |
| Barato |
| No Invasivo |
| Decrementa mortalidad |
| Disponible para un gran espectro de la población |
| De fácil entrenamiento para los especialistas |
| Alta sensibilidad y especificidad |

Fuente [17]

Cuadro 2.2 – Características ideales para el método de detección temprana de cáncer de mama

superficiales regionales de la mama se puede detectar con imágenes de mama IR [62].

Desde 1982 la agencia del gobierno de los Estados Unidos responsable de la regulación de alimentos, medicamentos, cosméticos, aparatos médicos, productos biológicos y derivados sanguíneos (FDA) ha aprobado la obtención de imágenes IR (Termografía) como modalidad adjunta a la mamografía para el cáncer de mama [17], como se muestra en el Cuadro 2.1. Las características que hacen atractivo el método de detección temprana de cáncer de mama por termografía según lo definido por los Programas de Investigación Médica Dirigidos por el Congreso de Estados Unidos sobre el Cáncer de Mama se detallan en el Cuadro 2.2. La radiación infrarroja medida emitida por un punto de la piel se puede convertir directamente en un valor de temperatura que represente este punto y luego se mapee a un píxel en una imagen de color falso de la escena. El sensor térmico utilizado para capturar la radiación infrarroja varía según el tipo de cámara. La cámara calcula la temperatura del cuerpo humano basándose en tres componentes emitidos: la radiación del cuerpo, la radiación de los objetos que están en el vecindario y que se refleja en el cuerpo y la radiación del medio circundante.

Se deben establecer algunos parámetros en la cámara para que pueda estimar la influencia de la radiación del medio donde se obtienen las imágenes. Estos parámetros son: emisividad del cuerpo humano (es decir, alrededor de 0,98), temperatura ambiental, humedad relativa, rango de temperatura de operación y distancia entre la cámara y el cuerpo. La cámara convierte la radiación medida por su sensor en una matriz con valores de temperatura. La radiancia de la piel es una función exponencial de la temperatura de la superficie, que a su vez es un indicador del nivel de perfusión sanguínea dentro del cuerpo. Los cambios en la perfu-

sión sanguínea pueden ocurrir por una variedad de razones, como inflamación, angiogénesis y traumas previos [38, 19].

Las imágenes IR se pueden mostrar en escala de grises o en falso color según muchos

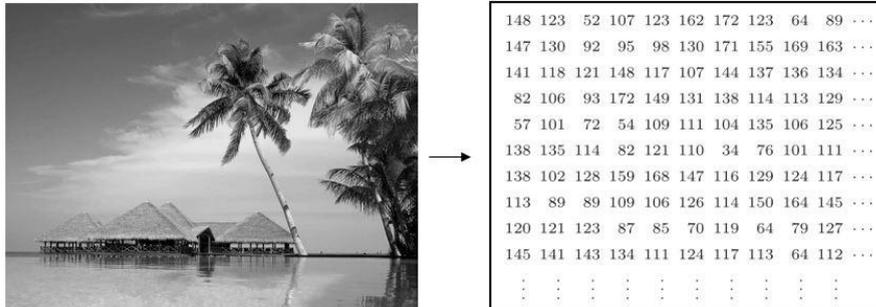


Figura 2.3 – Representación de una imagen digital

tipos de paletas, según la cámara o el software utilizado. El número de colores y los valores RGB de cada color difieren según la paleta utilizada. La temperatura asociada a cada punto de la superficie del pecho se puede aplicar en el análisis y en la detección de diferentes tipos de enfermedades. Estos aspectos deben ser examinados para revelar el comportamiento funcional en el caso de la distribución de calor normal o anormal [36].

En la actualidad es posible que muchos centros de salud y de investigación puedan costear una cámara térmica dado el gran desarrollo que se ha explicado, por lo cual la termografía puede ser ocupada como un complemento de otros estudios para tener un mejor diagnóstico, como la mamografía. Se ha demostrado que sistemas de diagnóstico asistido por computador que incorporan información física, mamográfica y termográfica del paciente pueden incrementar la detección de cáncer hasta en un 95 % [33].

2.2. Procesamiento de Imágenes Digitales

En esta tesis se tiene como propósito extraer información relevante de las imágenes de los termogramas que podrían indicar a qué clasificación térmica pertenece cada paciente. Para lograr esto, se hace uso de algunas técnicas de procesamiento de imágenes digitales. El procesamiento digital de imágenes trata con el uso de diferentes algoritmos de computadora para obtener cierta información de una imagen, para obtener una mejor visualización, transformar los datos de una imagen, etc.

2.2.1. Imagen Digital

Una imagen digital se define formalmente en forma de una matriz bidimensional ordenada de enteros como se ve en la Figura 2.3. Dicho de manera más formal, una imagen

digital I es una función bidimensional de las coordenadas enteras $\mathbf{N} \times \mathbf{N}$ que se correlaciona con un rango de posibles valores de imagen (píxel) P , la ecuación 2.1 la define [13].

$$I(u,v) \in P \quad \text{y} \quad u,v \in \mathbf{N} \tag{2.1}$$

| Canales | Bits/pix | Rango | Tipo |
|---------|----------|---------------|------------------|
| 1 | 1 | 0...1 | Binaria |
| 1 | 8 | 0...255 | Escala de Grises |
| 3 | 24 | $[0...255]^3$ | RGB |
| 4 | 32 | $[0...255]^4$ | CMYK |

Fuente [13]

Cuadro 2.3 – Tipos de imágenes con base en su profundidad de bits

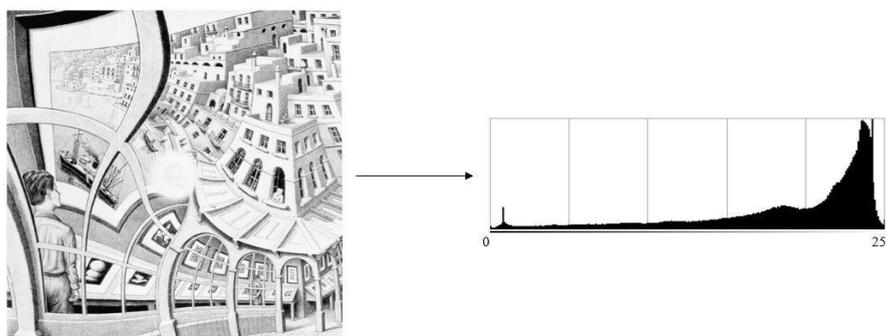


Figura 2.4 – Histograma de una imagen

La información dentro de un elemento de imagen depende del tipo de datos utilizado para representarlo. Los valores de píxeles son prácticamente siempre palabras binarias de longitud k por lo que un píxel puede representar cualquiera de 2^k valores diferentes. El valor k se llama profundidad de bits (o solo 'profundidad') de la imagen. El diseño exacto a nivel de bit de un píxel individual depende del tipo de imagen; por ejemplo, binario, escala de grises, o color RGB [13]. Las propiedades de algunos tipos de imágenes comunes se resumen en el Cuadro 2.3.

2.2.2. Histograma

Los histogramas se utilizan para representar las estadísticas de la imagen en un formato visual de fácil interpretación. Con un histograma, es fácil determinar ciertos tipos de problemas en una imagen, por ejemplo, es simple concluir si una imagen se expone adecuadamente mediante una inspección visual de su histograma. Los histogramas en general son distribuciones de frecuencias, y los histogramas de imágenes describen la frecuencia de los valores de intensidad que ocurren en una imagen. Este concepto se puede explicar fácilmente considerando una imagen antigua en escala de grises como la que se muestra en la Figura

2.4. Un histograma h para una imagen en escala de grises I con valores de intensidad en el rango $I(u, v) \in [0, K-1]$ contendría exactamente K entradas, donde para una imagen típica en escala de grises de 8 bits, $K=2^8 = 256$. Cada entrada de histograma individual representa el número de píxeles que tiene un valor de intensidad. Se define al histograma formalmente en la ecuación 2.2.

$$h(i) = \text{card}\{(u, v) \mid I(u,v) = i\} \tag{2.2}$$

2.2.3. Método de umbralización Otsu

La búsqueda de un umbral de forma automática es un área de investigación tradicional y aún muy activa que tuvo su pico en los años ochenta y noventa. Numerosas técnicas se han desarrollado para esta tarea, que van desde simples soluciones ad-hoc a algoritmos complejos con sólidos fundamentos teóricos. La binarización de imágenes también se considera una técnica de segmentación y, por lo tanto, a menudo se clasifica bajo este término. [14].

Uno de estos algoritmos es el de Otsu [49] que asume que la imagen original contiene píxeles de dos clases, cuyas distribuciones de intensidad son desconocidas. El objetivo es encontrar un umbral q tal que las distribuciones de fondo y primer plano resultantes estén separadas al máximo, lo que significa que son cada una lo más estrecha posible (tienen varianzas mínimas) y sus centros (medios) son más distantes de cada uno [14].

Sea $h(g)$ la función que denota el histograma de una imagen en escala de grises I con un total de N píxeles y K posibles valores de intensidad $0 \leq g < K$. Si establecemos el umbral de la imagen en el nivel q ($0 \leq q < K$), el conjunto de píxeles se divide en los subconjuntos disjuntos C_0, C_1 , que corresponden al fondo y al primer plano. La cantidad de píxeles asignados a cada subconjunto es [14]

$$n_0(q) = |C_0| = \sum_{g=0}^q h(g) \quad \text{y} \quad n_1(q) = |C_1| = \sum_{g=q+1}^{K-1} h(g) \tag{2.3}$$

Para cualquier umbral q , los valores medios de los píxeles en las particiones correspondientes C_0, C_1 se pueden calcular a partir del histograma como

$$\mu_0(q) = \frac{1}{n_0(q)} \cdot \sum_{g=0}^q g \cdot h(g) \tag{2.4}$$

$$\mu_1(q) = \frac{1}{n_1(q)} \cdot \sum_{g=q+1}^{K-1} g \cdot h(g) \tag{2.5}$$

Del mismo modo, las variaciones de las particiones de fondo y primer plano se pueden extraer del histograma como

$$\sigma_0^2(q) = \frac{1}{n_0(q)} \cdot \sum_{g=0}^q (g - \mu_0(q))^2 \cdot h(g) \tag{2.6}$$

$$\sigma_1^2(q) = \frac{1}{n_1(q)} \sum_{g=q+1}^{\bar{X}-1} (g - \mu_1(q))^2 \cdot h(g) \quad (2.7)$$

Para un umbral dado q , las varianzas de las particiones de fondo y en primer plano correspondientes se pueden calcular directamente desde el histograma de la imagen. El ancho combinado de las dos distribuciones se mide por la varianza dentro de la clase [14]

$$\sigma_w^2(q) = P_0 \cdot \sigma_0^2 + P_1(q) \cdot \sigma_1^2(q) = \frac{1}{N} [n_0(q) \cdot \sigma_0^2 + n_1(q) \cdot \sigma_1^2(q)] \quad (2.8)$$

donde

$$P_0(q) = \sum_{i=0}^q p(i) = \frac{1}{N} \cdot \sum_{i=0}^q h(i) = \frac{n_0(q)}{N} \quad (2.9)$$

$$P_1(q) = \sum_{i=q+1}^{K-1} p(i) = \frac{1}{N} \cdot \sum_{i=q+1}^{K-1} h(i) = \frac{n_1(q)}{N} \quad (2.10)$$

son las probabilidades de clase para C_0, C_1 , respectivamente. Por lo tanto, la varianza dentro de la clase es simplemente la suma de las varianzas individuales ponderadas por las correspondientes probabilidades de clase. Análogamente, la varianza entre clases [14],

$$\sigma_b^2(q) = P_0(q) \cdot (\mu_0(q) - \mu_I)^2 + P_1(q) \cdot (\mu_1(q) - \mu_I)^2 = \frac{1}{N} [n_0(q) \cdot (\mu_0(q) - \mu_I)^2 + n_1(q) \cdot (\mu_1(q) - \mu_I)^2] \quad (2.11)$$

mide las distancias entre los medios del grupo μ_0, μ_1 y la media global μ_I . La varianza total de la imagen σ_I^2 es la suma de la varianza dentro de la clase y la varianza entre clases,

$$\sigma_I^2 = \sigma_w^2 + \sigma_b^2 \quad (2.12)$$

Como σ_I^2 es constante para una imagen dada, el umbral q se puede encontrar minimizando la varianza dentro de σ_w^2 o maximizando la varianza entre σ_b^2 . La elección natural es maximizar σ_b^2 , ya que solo se basa en estadísticas de primer orden. Dado que la media global μ_I puede ser expresada como la suma ponderada de las particiones de las medias μ_0 y μ_1 , la ecuación se puede simplificar como

$$\sigma_b^2 = P_0(q) \cdot P_1(q) \cdot [\mu_0(q) - \mu_1(q)]^2 = \frac{1}{N^2} \cdot n_0(q) \cdot n_1(q) \cdot [\mu_0(q) - \mu_1(q)]^2 \quad (2.13)$$

El umbral óptimo se encuentra maximizando la expresión para la varianza entre clases con respecto a q , minimizando así la varianza dentro de la clase. Mientras una de las dos clases esté vacía ($n_0(q) = 0$ o $n_1(q) = 0$), la varianza entre clases resultante $\sigma_b^2(q)$ es cero. Se devuelve el umbral que produce la máxima varianza entre clases (σ_{bmx}^2), o -1 si no se puede

encontrar un umbral válido. Esto ocurre cuando todos los píxeles de la imagen tienen la misma intensidad, es decir, todos los píxeles están en el fondo o en la clase de primer plano.

2.2.4. Mejora de Contraste Acumulativo

La mejora del contraste es una operación de punto, esto quiere decir su tarea es modificar los píxeles de modo que el rango disponible de valores esté completamente cubierto. Esto se hace mapeando los píxeles más oscuros y brillantes actuales a los valores de intensidad

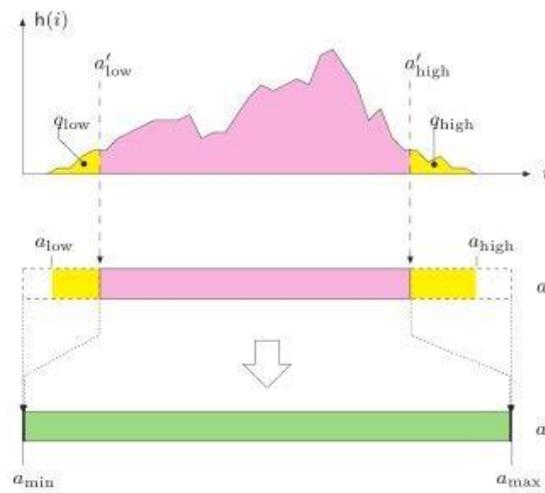


Figura 2.5 – Operación de auto-contraste. Fuente [13]

más bajos y más altos disponibles, respectivamente, y distribuyendo linealmente los valores intermedios [13].

Existen muchas técnicas para realizar una mejora de contraste, la aplicada en este trabajo es la de auto-contraste modificado. La técnica toma como referencia la función de mapeo definida en [13] como:

$$f_{ac}(a) = a_{min} + (a - a_{low}) \cdot \frac{a_{max} - a_{min}}{a_{high} - a_{low}} \quad (2.14)$$

donde el rango total de intensidades en la imagen lo es $[a_{min}, a_{max}]$, a_{low} es el valor más pequeño que tiene un pixel en la imagen y a_{max} es el valor más grande que tiene un pixel en la imagen. Sin embargo en la práctica, la función de mapeo f_{ac} podría verse fuertemente influenciada por solo unos pocos valores de píxeles extremos (bajos o altos), que pueden no ser representativos del contenido de la imagen principal. Esto se puede evitar en gran medida mediante la 'saturación' de un porcentaje fijo (s_{low}, s_{high}) de píxeles en los extremos superior e inferior del rango de intensidad del objetivo. Para lograr esto, determinamos dos valores

límite a_{low}^0, a_{high}^0 de tal manera que un cuantil predefinido q_{low} de todos los valores de píxel

en la imagen I sea más pequeño que un a_{low}^0 y otro cuantil q_{high} de los valores son mayores

que a_{high}^0 (Figura 2.5). Los valores a_{low}^0, a_{high}^0 depende del contenido de la imagen y se puede

obtener fácilmente a partir del histograma acumulativo $H(i)$ de la imagen [13]:

$$a_{low}^0 = \min\{i | H(i) \geq M \cdot N \cdot q_{low}\} \tag{2.15}$$

$$a_{high}^0 = \max\{i | H(i) \leq M \cdot N \cdot (1 - q_{low})\} \tag{2.16}$$

donde $0 \leq q_{low}, q_{high} \leq 1, q_{low} + q_{high} \leq 1$ y $M \cdot N$ es el número de píxeles en la imagen. Todos los valores fuera (e incluidos) en a_{low} y a_{high} son mapeados a los valores extremos a_{min} y a_{max} respectivamente, y los valores intermedios son mapeados linealmente al intervalo $[a_{min}, a_{max}]$. El histograma acumulativo lo obtenemos con la siguiente expresión

$$H(i) = \sum_{j=0}^i h(j) \quad \text{para } 0 \leq i < K \quad (2.17)$$

donde $h(j)$ es el valor del histograma original para la intensidad con valor i , así el histograma acumulativo es la suma de todos los valores $h(j)$ con $j \leq i$. La función de mapeo f_{mac} para la operación de auto contraste modificado se define como [13]

$$f_{mac} = \begin{cases} a_{min} & \text{para } a \leq a_{low} \\ a_{min} + (a - a_{low}) \cdot \frac{a_{max} - a_{min}}{a_{high} - a_{low}} & \text{para } a_{low} < a < a_{high} \\ a_{max} & \text{para } a \geq a_{high} \end{cases} \quad (2.18)$$

Al usar esta formulación, el mapeo a intensidades mínima y máxima no depende únicamente de píxeles extremos singulares, sino que puede basarse en un conjunto representativo de píxeles. Por lo general, se toma el mismo valor para los cuantiles superior e inferior (es decir, $q_{low} = q_{high} = q$), con $q = 0.005 \dots 0.015$ (0.5 ... 1.5 %) siendo valores comunes [13].

2.2.5. Segmentación

La segmentación de imágenes es el primer paso de la extracción de características y también una de las tareas más críticas del análisis de imágenes. Tiene el objetivo de extraer información (representada por datos) de una imagen a través de la segmentación de imágenes, la representación de objetos y la medición de características. Es evidente que los resultados de la segmentación tendrán una influencia considerable sobre la precisión de la medición de características [64].

La segmentación de imágenes a menudo se describe como el proceso que subdivide una imagen en sus partes constituyentes y extrae aquellas partes de interés (objetos). Es una de las tareas más críticas en el análisis automático de imágenes porque los resultados de la segmentación afectarán todos los procesos subsiguientes de análisis de imágenes, como representación y descripción de objetos, medición de características e incluso las siguientes tareas de nivel superior, como la clasificación de objetos y la interpretación de escenas [65].

Teniendo en cuenta la segmentación de imágenes como la partición de una imagen en un conjunto de regiones no solapadas cuya unión es la imagen completa, algunas reglas que deben seguirse para las regiones resultantes de la segmentación de imágenes pueden

establecerse son [30]:

- Deben ser uniformes y homogéneos con respecto a algunas características;

- Sus interiores deben ser simples y sin muchos agujeros pequeños;
- Las regiones adyacentes deberían tener valores significativamente diferentes con respecto a la característica sobre la cual son uniformes; y
- Los límites de cada segmento deben ser simples, no irregulares, y deben ser espacialmente precisos.

Una definición formal de segmentación de imágenes, suponiendo que la imagen completa está representada por R y R_i , donde $i = 1, 2, \dots, n$ son regiones disjuntas no vacías de R , consta de las siguientes condiciones [21]:

- $\bigcup_{i=1}^n R_i = R$;
- Para todo $i \neq j, i \neq j, \exists R_i \cap R_j = \emptyset$;
- Para $i = 1, 2, \dots, n$, tiene que tener $P(R_i) = \text{TRUE}$;
- Para todo $i \neq j, \exists P(R_i \cup R_j) = \text{FALSE}$;
- Para todo $i = 1, 2, \dots, n, R_i$ es un componente conectado

Con tantos algoritmos que se han desarrollado, la clasificación de varias técnicas para la segmentación de imágenes se convierte en una tarea esencial. Se han propuesto diferentes esquemas. Por ejemplo, los algoritmos de segmentación se han dividido en tres grupos [21].

- Umbral o agrupamiento (este último es la extensión multidimensional del anterior)
- Detección de bordes
- Extracción de la región

2.2.6. Interpolación de Lagrange

La interpolación es el proceso de estimación de los valores intermedios de una función o señal muestreada en posiciones continuas o el intento de reconstruir la función continua original de un conjunto de muestras discretas. El objetivo concreto es obtener una estimación óptima para el valor de la función de una imagen bidimensional $I(x, y)$ en cualquier posición continua $(x, y) \in \mathbf{R}^2$. En la práctica, la función interpolada debe conservar la mayor cantidad posible de detalles (es decir, nitidez) sin causar artefactos visibles [12].

El polinomio de interpolación de Lagrange es el polinomio $P(x)$ de grado $\leq (n-1)$ que pasa por los n puntos $(x_1, y_1 = f(x_1)), (x_2, y_2 = f(x_2)), \dots, (x_n, y_n = f(x_n))$, y está dado por

$$P(x) = \sum_{j=1}^n P_j(x) \quad \text{donde} \quad P_j(x) = y_j \prod_{k \neq j} \frac{x - x_k}{x_k - x_j} \tag{2.19}$$

$$j=1$$

$$\sum_{k=1}^{k=6} x_j - x_k$$

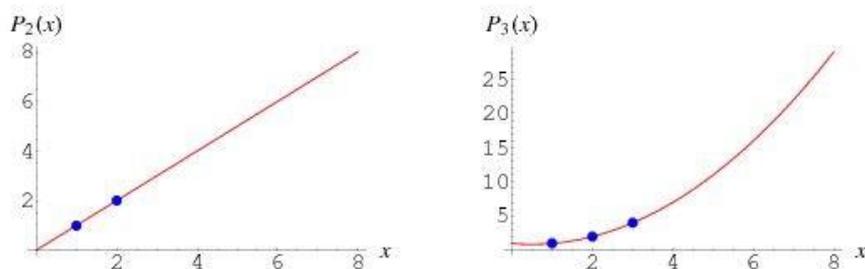


Figura 2.6 – Ejemplos con interpolación de Lagrange

La fórmula fue publicada por primera vez por Waring (1779), redescubierta por Euler en 1783 y publicada por Lagrange en 1795 [32]. Algunos ejemplos se muestran en la Figura 2.6

2.2.7. Extracción de Características

Para reconocer o clasificar una imagen del objetivo, primero se deben extraer algunas características de la imagen y luego usar estas características dentro de un clasificador de patrones para obtener la clase final. La extracción de características (o detección) busca ubicar regiones de características significativas en las imágenes, dependiendo de sus características y aplicaciones intrínsecas. Estas regiones se pueden definir en vecindarios globales o locales y se distinguen por formas, texturas, tamaños, intensidades, propiedades estadísticas, etc. Los métodos de extracción de características locales se dividen en métodos con base en la intensidad y en la estructura. Los métodos basados en la intensidad analizan los patrones de intensidad locales para encontrar regiones que satisfagan los criterios de estabilidad o singularidad deseados. Los métodos basados en estructuras detectan estructuras de imágenes como bordes, líneas, esquinas, círculos, elipses, etc. La extracción de características tiende a identificar las características que pueden formar una buena representación del objeto [58].

En esta tesis las características que se van a extraer son de primer orden y las que se basan en la textura, a continuación se describen las características.

2.2.8. Características de Primer Orden

La principal clase de característica extraída depende de la suposición de que la textura se puede definir por las propiedades estadísticas locales de un píxel en escala de grises. A partir del histograma de la imagen se pueden derivar los estadísticos de primer orden y usarse como características de textura.

La información estadística de primer orden se deriva del histograma de la imagen de detalles. Como observó Mallat [5], estos histogramas de detalles obtenidos a partir de texturas

naturales pueden ser modelados por una familia de funciones exponenciales. A continuación se listan las funciones ocupadas y su definición formal.

- **Media.** Es la medida de tendencia central más conocida y comúnmente llamada 'promedio'. Se define formalmente como [55]

$$\mu = \frac{\sum_{i=1}^n P(i)}{n} \tag{2.20}$$

donde $P(i)$ es el i -ésimo valor del histograma o conjunto de datos y n es el número de niveles de intensidad o totalidad de datos

- **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. Si el número de elementos de la muestra es impar, la mediana es el valor medio o central siempre y cuando todos estos elementos sean ordenados por magnitud, cuando el número de elementos es par, no existe un valor medio único, si no que existen 2 valores medios. Para este caso, la mediana corresponde a la media de esos dos valores centrales, cuando todos los valores son ordenados. Es decir, la mediana del conjunto de datos es la $\frac{n+1}{2}$ -ésima observación, cuando las observaciones han sido ordenadas [55].

- **Desviación Estándar.** La dispersión de un conjunto de valores se refiere a la variedad que muestran éstos. Una medida de dispersión nos indica la variabilidad que está presente en el conjunto de datos. La medida de dispersión que se utiliza es la desviación estándar y se define como [55]

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (P(i) - \mu)^2}{n - 1}} \tag{2.21}$$

donde $P(i)$ es el i -ésimo valor del histograma o conjunto de datos, n es el número de niveles de intensidad o totalidad de datos y μ es la media

- **Curtosis.** La curtosis se mide promediando la cuarta potencia de la diferencia entre cada elemento del conjunto y la media, dividido entre la desviación típica elevado también a la cuarta potencia. El coeficiente de curtosis será [2]

$$\mu^4 = \frac{\sum_{i=1}^n (P(i) - \mu)^4}{n\sigma^4} - 3 \tag{2.22}$$

donde $P(i)$ es el i -ésimo valor del histograma o conjunto de datos, n es el número de niveles de intensidad o totalidad de datos y σ es la desviación estándar simple

- **Asimetría.** La asimetría se mide promediando la tercera potencia de la diferencia entre cada elemento del conjunto y la media, dividido entre la desviación típica elevado también a la tercera potencia. El coeficiente de asimetría será [2]

$$\mu^3 = \frac{\sum_{i=1}^n (P(i) - \mu)^3}{n\sigma^3} \quad (2.23)$$

donde $P(i)$ es el i -ésimo valor del histograma o conjunto de datos, n es el número de niveles de intensidad o totalidad de datos y σ es la desviación estándar simple

Máximo. Es el valor más grande del conjunto de datos o del histograma ($\max(P(i))$)

Mínimo. Es el valor más pequeño del conjunto de datos o del histograma ($\min(P(i))$)

Entropía. La entropía se define formalmente como

$$entropía = - \sum_{i=1}^X P(i) * \log P(i) \tag{2.24}$$

donde $P(i)$ es el i -ésimo valor del histograma o conjunto de datos, n es el número de niveles de intensidad o totalidad de datos

Energía. La energía se define formalmente como

$$energía = \sum_{i=1}^X P(i)^2 \tag{2.25}$$

donde $P(i)$ es el i -ésimo valor del histograma o conjunto de datos, n es el número de niveles de intensidad o totalidad de datos

2.2.9. Características de Segundo Orden

Los estadísticos de segundo orden pueden mejorar la discriminación de texturas. La información textural en una imagen está contenida en la relación espacial que los tonos de gris tienen entre ellos. Esas relaciones están especificadas en la matriz de co-ocurrencia de niveles de gris (GLCM) que son computadas en una dirección específica (o bien para todas: 0°, 45°, 90° y 135°) entre los píxeles vecinos dentro de una ventana móvil dentro en la imagen. Este método permite extraer una gran cantidad de información de textura de imagen por la gran variedad de descriptores que es posible obtener de esta matriz, que hacen posible caracterizar con un conjunto de valores cuantificables cada imagen analizada.

La textura GLCM considera la relación entre dos píxeles a la vez, llamada la referencia y el píxel vecino. Esto también se puede expresar como una relación (1,0): 1 píxel en la dirección x, 0 píxeles en la dirección y. Cada píxel dentro de la ventana se convierte en el píxel de referencia a su vez, comenzando en la esquina superior izquierda y avanzando hacia la esquina inferior derecha. Los píxeles a lo largo del borde derecho no tienen lado derecho, por lo que no se utilizan para este conteo. La Figura 2.7 muestra una relación de este tipo: el valor de píxel que se muestra en rojo son píxeles de referencia y los píxeles que se muestran en azul son píxeles vecinos en una relación (1,0) con respecto a su píxel de referencia [28].

Para generalizar el Cuadro 2.4 muestra las combinaciones de los niveles de gris que son posibles para la imagen y su posición en la matriz. El cuadro se interpreta de la siguiente forma. La celda superior izquierda se rellenará con el número de veces que aparece la combinación

0,0, es decir, cuántas veces dentro del área de la imagen un píxel con un nivel de gris 0 (píxel vecino) cae a la derecha de otro píxel con nivel gris 0 (referencia píxel). Cada celda se lee en

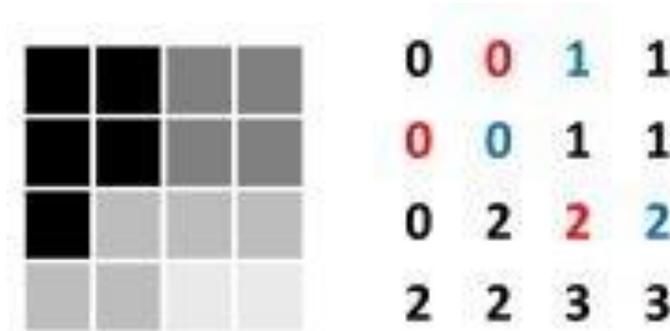


Figura 2.7 – Ejemplo de creación de GLMC

| Valor de Pixel Vecino Pixel de Referencia | 0 | 1 | 2 | 3 |
|--|-----|-----|-----|-----|
| 0 | 0,0 | 0,1 | 0,2 | 0,3 |
| 1 | 1,0 | 1,1 | 1,2 | 1,3 |
| 2 | 2,0 | 2,1 | 2,2 | 2,3 |
| 3 | 3,0 | 3,1 | 3,2 | 3,3 |

Cuadro 2.4 – Combinaciones de GLMC

este patrón con los cambios apropiados en los números. Por otro lado un proceso muy común a realizar en la GLMC es la normalización de sus valores, que no es otra cosa que dividir cada valor entre la suma de los valores. La expresión formal de la normalización de los valores de la GLMC es de la siguiente forma

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \tag{2.26}$$

donde $P_{i,j}$ corresponde a la entrada i,j normalizada de la matriz, $V_{i,j}$ es el valor original de la entrada i,j de la matriz y N es el número total de filas y columnas.

Haralick et al. [29] propuso 14 métricas diferentes. Incluyen la varianza calculada sobre la suma de píxeles adyacentes; varianza en la diferencia entre píxeles adyacentes; entropía en la suma y en la diferencia; correlación que involucra entropías y el coeficiente de correlación máximo. A continuación se listan cinco de esas catorce métricas que fueron ocupadas en la investigación.

- **Homogeneidad.** Momento de diferencia inversa, se define

$$homogeneity = \frac{\sum_{i,j=0}^{N-1} (P_{i,j})}{2} \tag{2.27}$$

$$i,j=0 \ 1+(i-j)$$

donde $P_{i,j}$ corresponde a la entrada i,j normalizada de la matriz

- Entropía.** El concepto proviene de la termodinámica. Se refiere a la cantidad de energía que se pierde permanentemente por calor ('caos') cada vez que ocurre una reacción o transformación física. La entropía no se puede recuperar para hacer un trabajo útil. Debido a esto, el término se usa de forma no técnica para decir desorden. La definición formal es

$$entropy = \sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \tag{2.28}$$

donde $P_{i,j}$ corresponde a la entrada i,j normalizada de la matriz, \ln es el logaritmo natural y debido a que $\ln(0)$ es indefinido se toma como convención que $0 * \ln(0) = 0$

- Energía.** La energía se puede usar para hacer un trabajo útil, ya que representa orden. Esta es la razón por la cual 'Energía' se usa para la textura que aumenta al aumentar el orden en la imagen. Los valores altos de energía ocurren cuando la ventana está muy ordenada, la definición es la siguiente

$$energy = \sum_{i,j=0}^{N-1} (P_{i,j})^2 \tag{2.29}$$

donde $P_{i,j}$ corresponde a la entrada i,j normalizada de la matriz

- Contraste.** También se llama 'varianza de suma de cuadrados' y ocasionalmente 'inercia', se define formalmente

$$contrast = \sum_{i,j=0}^{N-1} (P_{i,j})^2 \tag{2.30}$$

donde $P_{i,j}$ corresponde a la entrada i,j normalizada de la matriz

- Correlación.** La textura de correlación mide la dependencia lineal de los niveles de gris en los de pixeles vecinos, se define de la siguiente forma

$$correlation = \sum_{i,j=0}^{N-1} \frac{h(i-\mu_i)(j-\mu_j) \mathbf{i}}{(P_{i,j})^2 \mathbf{q}(\sigma^2)(\sigma^2)} \tag{2.31}$$

$$i \quad j$$

donde $P_{i,j}$ corresponde a la entrada i,j normalizada de la matriz, μ es la media de la columna o la fila y σ es la varianza de la columna o la fila

2.3. Aprendizaje Automático

En esta tesis se propone una metodología para la extracción de características, la forma de probarlas es a través de un proceso de clasificación con técnicas de aprendizaje automático, es por ello que es necesario definir esta área del conocimiento y algunos conceptos relacionados. El aprendizaje automático aborda la cuestión de cómo crear programas informáticos que mejoren su rendimiento en alguna tarea a través de la experiencia [42].

2.3.1. Aprendizaje supervisado

Los algoritmos más exitosos de aprendizaje automático son los procesos de toma de decisión al generalizar desde ejemplos conocidos. Este tipo de aprendizaje automático es el de aprendizaje supervisado, el usuario provee al algoritmo con pares de entradas y salidas deseadas, y el algoritmo busca una forma de producir una salida para una entrada dada. En particular el algoritmo es capaz de crear una salida para una entrada que no haya sido introducida previamente, esto sin ningún tipo de asistencia o retroalimentación de algún usuario [47]. Dentro de este tipo de aprendizaje existen diversos algoritmos propuestos para generar un modelo de clasificación, en esta investigación se hace uso de una Red Neuronal Artificial.

2.3.2. Redes Neuronales Artificiales

Nuestros cerebros nos hacen inteligentes; vemos u oímos, aprendemos y recordamos, planificamos y actuamos gracias a nuestro cerebro. Al tratar de construir máquinas para tener tales habilidades, nuestra fuente inmediata de inspiración es el cerebro humano, así como los pájaros fueron la fuente de inspiración en nuestros primeros intentos de volar. Lo que nos gustaría hacer es observar cómo funciona el cerebro y tratar de llegar a una comprensión de cómo se hace lo que hace [10]. El cerebro humano se compone de un gran número de unidades de procesamiento, llamadas neuronas, y cada neurona está conectada a un gran número de otras neuronas a través de conexiones llamadas sinapsis. En la década de 1960, el modelo de perceptrón se propuso como un modelo para el reconocimiento de patrones [54]. Es una red compuesta por neuronas artificiales y conexiones sinápticas, donde cada neurona tiene un valor de activación, y una conexión de la neurona A a la neurona B tiene un peso que define el efecto de A sobre B. Si la sinapsis es excitatoria, cuando A está activa, también intenta activar B; si la sinapsis es inhibitoria, cuando A está activa, intenta suprimir B [10].

Durante la operación, cada neurona resume las activaciones de todas las neuronas que hacen una sinapsis con ella, ponderada por sus pesos sinápticos, y si la activación total es mayor que un valor umbral, la neurona se 'dispara' y su salida corresponde al valor de esta

activación; de lo contrario, la neurona está en silencio. Si la neurona se dispara, envía su valor de activación a la vez a todas las neuronas con las que hace una sinapsis. La Figura 2.8 muestra el diagrama de una red neuronal.

El perceptrón básicamente calcula una suma ponderada antes de tomar una decisión. Tales neuronas se pueden organizar como capas donde todas las neuronas de una capa toman la entrada de todas las neuronas en la capa anterior y calculan su valor en paralelo, y estos valores en conjunto se alimentan a todas las neuronas en la capa que sigue: esto se llama un perceptrón multicapa [10].

Los nodos interconectados están organizados en capas. La organización general de una red neuronal es una capa de entrada, que corresponde al número de ejemplos dados a la red neuronal para entrenar; una o más capas ocultas, y una capa de salida, el número de salidas corresponde a la cantidad de clases existentes. Clásicamente hay dos modos operacionales

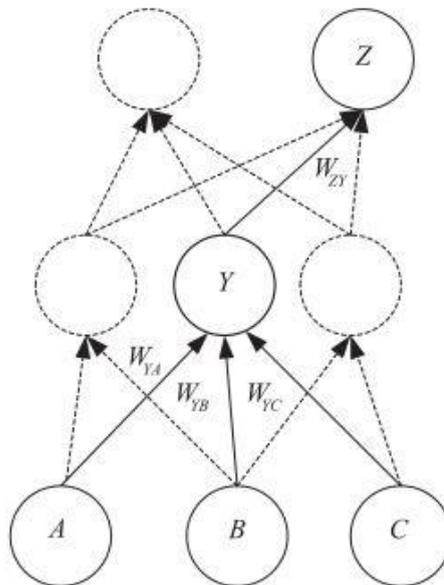


Figura 2.8 – Diagrama de una Red Neuronal

distinguidos en los sistemas neuronales: prueba y entrenamiento. El entrenamiento es el proceso donde se realizan los ajustes de los hiperparámetros de la red. En general, esta fase de aprendizaje consiste en determinar un conjunto de pesos sinápticos que permite a la red aproximarse correctamente al objetivo (resultado deseado). Después de que el sistema ha sido entrenado, por lo general, los pesos y la estructura de la red neuronal permanecen fijos, listos para procesar datos; esto se llama fase de prueba. Dos o más neuronas se pueden organizar en una capa, también, múltiples capas de neuronas se pueden utilizar en una sola red neuronal, esto es lo que define la arquitectura del sistema. La arquitectura de la red define la forma en que las unidades comparten información.

El caso más simple es el de una red que tiene dos entradas y una salida, como se aprecia en la Figura 2.9. La salida de la red está formada por la activación de la neurona de salida que se expresa como una función F de la entrada, la siguiente ecuación denota la activación de la neurona de la salida como [35]:

$$y = F\left(\sum_{i=1}^n w_i x_i + \theta\right) \quad (2.32)$$

La función de activación F puede ser lineal o no lineal. Por ejemplo si se considera una función que retorne un valor +1 o -1, entonces la red puede ser usada para tareas de clasificación, así la separación entre dos clases en este caso sería una línea recta que está dada por la ecuación 2.33 [35]:

$$w_1 x_1 + w_2 x_2 + \theta = 0 \quad (2.33)$$

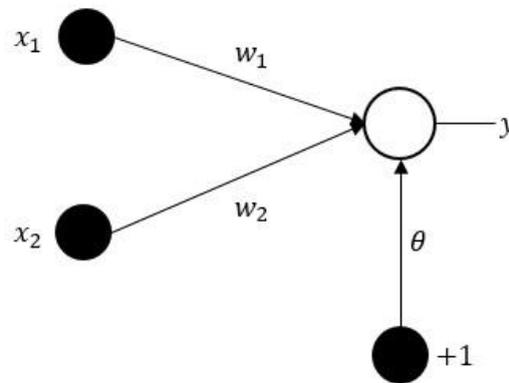


Figura 2.9 – Red de una capa con una salida y dos entradas

La única capa en la red representa en este caso una función lineal discriminante, los valores w_1 y w_2 son los pesos que ayudan a optimizar la mejor separación entre las dos clases y el valor θ es un valor ayuda a maximizar el umbral entre las dos clases. Los pesos y el valor de umbral θ son ajustados de forma iterativa. Para cada peso el nuevo valor es calculado al sumar una corrección al valor anterior. El valor umbral es actualizado de la misma forma. Las ecuaciones 2.34 y 2.35 denotan la forma de ajustar los valores [35].

$$w_i(t + 1) = w_i(t) + \Delta w_i(t), \tag{2.34}$$

$$\theta(t + 1) = \theta(t) + \Delta \theta(t) \tag{2.35}$$

De tal forma que la regla (algoritmo) de aprendizaje del perceptrón en una tarea de aprendizaje es simple y se detalla a continuación. Teniendo como entrada un vector x y una salida deseada $d(x)$, se realiza el siguiente proceso hasta que el error sea menor o igual a un umbral establecido o durante el número de iteraciones o épocas que se definan.

1. Inicializar de forma aleatoria los pesos para las conexiones
2. Seleccionar una instancia del vector x del conjunto de entrenamiento
3. Si $y \neq d(x)$ (el perceptrón da una respuesta incorrecta), modificar todas las conexiones w_i de acuerdo a $\Delta w_i = d(x)x_i$
4. Regresar al paso 2

Además de modificar los pesos también hay que ajusta el valor θ . Este valor se considera como una conexión w_0 entre la neurona de salida y una unidad *dummy* que siempre se establece en $x_0 = 1$. Dada la regla de aprendizaje del perceptrón, el valor θ se ajusta de acuerdo a la ecuación 2.36 [35].

$$\Delta\theta = \begin{cases} 0 & y = d(x) \\ d(x) & y \neq d(x) \end{cases} \quad (2.36)$$

El perceptrón es limitado en muchos casos es por ello que se desarrolló un modelo multicapa (una capa de entrada, una de salida y n capas *ocultas*) y con propagación de errores hacia atrás. La idea central detrás de esta solución es que los errores para las unidades de la capa oculta se determinan retrocediendo los errores de las unidades de la capa de salida. Por esta razón, el método a menudo se denomina regla de aprendizaje de retro-propagación. La propagación hacia atrás también se puede considerar como una generalización de la regla Δ para las funciones de activación no lineales y las redes de múltiples capas.

El proceso de retro-propagación es intuitivamente muy claro. Lo que sucede en las ecuaciones anteriores es lo siguiente: cuando se fija un patrón de aprendizaje, los valores de activación se propagan a las unidades de salida y la salida de la red real se compara con los valores de salida deseados. Generalmente terminamos con un error en cada una de las unidades de salida. Vamos a llamar a este error e_0 para una unidad de salida particular o . Tenemos que llevar e_0 a cero.

El método más simple para hacer esto es el método voraz: nos esforzamos por cambiar las conexiones en la red neuronal de tal manera que, la próxima vez, el error e_0 será cero para este patrón en particular. Para adaptar los pesos de la entrada a unidades ocultas, nuevamente queremos aplicar la regla Δ . En este caso, sin embargo, no tenemos un valor de δ para las unidades ocultas. Esto se resuelve mediante la regla de cadena que hace lo siguiente: distribuye el error de una unidad de salida o a todas las unidades ocultas a las que está conectado, ponderado por esta conexión. Finalmente la función de activación de la unidad oculta; f_t debe aplicarse al delta, antes de que el proceso de propagación hacia atrás pueda continuar.

Cuando se trabaja con redes de retro-propagación aparte de considerar el ajuste los pesos y la función de activación, se consideran dos parámetros clave, la tasa de aprendizaje que tiene como propósito evitar que nuestra solución sea un óptimo local y no un óptimo global, permitiendo realizar *saltos* en las iteraciones durante el proceso de entrenamiento. El otro parámetro es el momentum, cuando no se utiliza el momentum, transcurre mucho tiempo antes de que se alcance el mínimo con una tasa de aprendizaje baja, mientras que para las altas tasas de aprendizaje nunca se alcanza el mínimo debido a las oscilaciones. Al agregar el término momentum, el mínimo se alcanzará más rápido [35].

2.3.3. Normalización de atributos

La normalización de características a menudo se requiere para neutralizar el efecto de las diferentes características cuantitativas que se miden en diferentes escalas. El método que se define es el de Min-Max.

Escalamiento Min-Max (a menudo también llamado simplemente 'normalización', una causa común de ambigüedades). En este enfoque, los datos se escalan a un rango fijo, por lo general de 0 a 1. El escalamiento de Min-Max es típicamente hecho a través de la siguiente ecuación [1]

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.37)$$

donde X_{min} es el valor más pequeño del conjunto de datos y X_{max} es el valor más grande del conjunto de datos.

2.3.4. Selección de Características

A menudo es una buena idea seleccionar un subconjunto adecuado de características antes del proceso de entrenamiento del algoritmo de clasificación. Esto no solo acelerará el aprendizaje, ya que se deben tener en cuenta menos características candidatas, sino que también ayuda a evitar el sobreajuste. Hay dos enfoques principales para la selección de características. El enfoque por *filtro* donde las características son cuantificadas a través de alguna métrica y las mejor evaluadas son seleccionadas. El otro enfoque es el de *envoltorio*, donde la idea es que la selección de atributos es 'envuelta' en un procedimiento de búsqueda que generalmente involucra el entrenamiento y evaluación de un modelo con un conjunto candidato de características [20].

El método de selección de características empleado en este trabajo sigue el enfoque de filtro. El algoritmo empleado es el de Selección de Características de Subconjuntos basado en correlaciones (CFS) [27] el cual evalúa el valor de un subconjunto de atributos al considerar la capacidad predictiva individual de cada característica junto con el grado de redundancia entre ellas. Se prefieren subconjuntos de características que están altamente correlacionadas con la clase mientras tienen baja intercorrelación. La ecuación que define formalmente la correlación entre los componentes analizados y una variable externa es

$$r_{zc} = \frac{k \overline{r_{zi}}}{k + k(k-1) \overline{r_{ii}}} \quad (2.38)$$

donde r_{zc} es la correlación de la suma de los componentes considerados y una variable externa, donde k es el número de componentes, $\overline{r_{zi}}$ es el promedio de las correlaciones entre los componentes y la variables externa y $\overline{r_{ii}}$ es el promedio de la intercorrelación entre los componentes.

2.3.5. Validación Cruzada

En la validación cruzada de *k-folds*, los datos iniciales se dividen al azar en k subconjuntos mutuamente excluyentes o 'pliegues', D_1, D_2, \dots, D_k , cada uno de aproximadamente del mismo tamaño. El entrenamiento y las pruebas se realizan k veces. En la iteración i , la

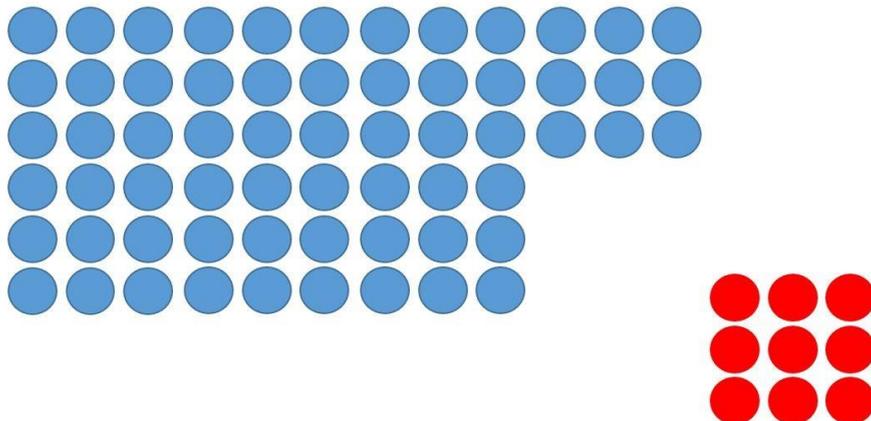


Figura 2.10 – Ejemplo de validación cruzada. En azul conjunto de entrenamiento, en rojo conjunto de prueba

partición D_i se reserva como el conjunto de prueba, y las particiones restantes se usan colectivamente para entrenar el modelo. Es decir, en la primera iteración, los subconjuntos D_2, \dots, D_k sirven colectivamente como el conjunto de entrenamiento para obtener un primer modelo, que se prueba en D_1 ; la segunda iteración se entrena en subconjuntos D_1, D_3, \dots, D_k y se prueba en D_2 ; y así.

A diferencia de los métodos de submuestreo remanente y aleatorio anteriores, aquí, cada muestra se usa la misma cantidad de veces para el entrenamiento y una vez para la prueba. Para la clasificación, la estimación de precisión es el número total de clasificaciones correctas de las iteraciones k , dividido por el número total de tuplas en los datos iniciales. Para la predicción, la estimación del error se puede calcular como la pérdida total de las iteraciones k , dividida por el número total de tuplas iniciales [63].

Un ejemplo visual de la validación cruzada está en la Figura 2.10. En general, se recomienda la validación cruzada estratificada de 10 veces para estimar la precisión (incluso si la potencia de cálculo permite usar más pliegues) debido a su sesgo y varianza relativamente bajos [63].

2.3.6. Métricas de validación

El uso de datos de entrenamiento para derivar un clasificador o predictor y luego para estimar la precisión del modelo aprendido resultante puede resultar en estimaciones excesivamente optimistas debido a la sobreajuste del algoritmo de aprendizaje en los datos. En cambio, la precisión se mide mejor en un conjunto de pruebas que consta de tuplas con etiquetas de clase que no se usaron para entrenar el modelo. La precisión de un clasificador en un conjunto de prueba dado es el porcentaje de tuplas del conjunto de prueba que el clasificador clasifica correctamente [63].

En la literatura de reconocimiento de patrones, esto también se conoce como la tasa de reconocimiento general del clasificador, es decir, refleja qué tan bien el clasificador reconoce las tuplas de las diversas clases. A continuación se listaran las herramientas y métricas para

| | | Clase Predicta | |
|--------------|-------|--------------------|----------------------|
| | | C_1 | C_2 |
| Clase Actual | C_1 | Verdadero Positivo | Falsos Negativos |
| | C_2 | Falsos Positivos | Verdaderos Negativos |

Cuadro 2.5 – Matriz de Confusión para tuplas negativas y positivas

analizar los resultados de un clasificador.

Matriz de Confusión

La matriz de confusión es una herramienta útil para analizar qué tan bien su clasificador puede reconocer tuplas de diferentes clases. En el Cuadro 2.5 se muestra una matriz de confusión para dos clases. Dadas m clases, una matriz de confusión es una tabla de al menos tamaño m por m . Una entrada, $CM_{i,j}$, en las primeras m filas y m columnas indica el número de tuplas de la clase i que el clasificador etiquetó como clase j . Para que un clasificador tenga buena precisión, idealmente la mayoría de las tuplas se representarían a lo largo de la diagonal de la matriz de confusión, desde la entrada $CM_{1,1}$ hasta la entrada $CM_{m,m}$, con el resto de las entradas cercanas a cero [63].

Sensibilidad, Especificidad y Precisión

Para poder saber qué tan bien el clasificador puede reconocer las tuplas positivas y qué tan bien puede reconocer las tuplas negativas. Las medidas de sensibilidad y especificidad se pueden usar, respectivamente, para este propósito. La sensibilidad también se conoce como la tasa positiva (reconocimiento) verdadera (es decir, la proporción de tuplas positivas que se identifican correctamente), mientras que la especificidad es la tasa negativa verdadera (es decir, la proporción de tuplas negativas que se identifican correctamente). Además, podemos usar la precisión para acceder al porcentaje de tuplas etiquetadas como verdaderas que en realidad son tuplas verdaderas. Estas medidas se definen como [63]

$$sensitivity = \frac{t_{pos}}{pos} \tag{2.39}$$

$$specificity = \frac{t_{neg}}{neg} \tag{2.40}$$

$$precision = \frac{t_{pos}}{(t_{pos} + f_{pos})} \tag{2.41}$$

donde t_{pos} es el número de verdaderos positivos, pos el número de tuplas positivas, t_{neg} es el número de verdaderos negativos, neg es el número de tuplas negativas y f_{pos} el número de falsos positivos. Finalmente puede ser mostrada la precisión global es una función de sensibilidad y especificidad:

$$accuracy = sensitivity \frac{pos}{(pos + neg)} + specificity \frac{neg}{(pos + neg)} \quad (2.42)$$

3 Estado del Arte

En este capítulo se presenta el estado del arte sobre investigaciones relacionadas a la clasificación de imágenes térmicas de pecho, se listan las técnicas usadas en los trabajos y al final se hace un análisis donde se hace énfasis en las características extraídas y el grupo al que pueden pertenecer esas características.

3.1. Trabajo relacionado

Los sistemas de ayuda de diagnóstico por ordenador (CAD) se han vuelto uno de los temas de mayor investigación en imágenes médicas y radiología. Estos sistemas se han empleado en padecimientos musculares, cardiacos o para algún tipo de cáncer por mencionar algunos. Generalmente los especialistas usan estos sistemas como una segunda opinión que suele brindar información útil para emitir un diagnóstico más certero [18].

En el caso de sistemas CAD para la detección de anomalías de mama, que puedan ayudar a prevenir o identificar cáncer de mama, y que ocupen imágenes térmicas se han hecho también muchas investigaciones, si bien se tiene claro que la sensibilidad de los dispositivos infrarrojos ha sido un tema controversial, los últimos avances han permitido obtener mejores resultados en combinación con distintas técnicas de aprendizaje automático, como lo son las redes neuronales, la minería de datos, la lógica difusa y el aprendizaje profundo entre otros [43].

Por ejemplo, Nahar et al. [48] realizan un análisis comparativo de varios algoritmos de inteligencia computacional para identificar el cáncer de mama en sus primeras etapas. Considera dos tipos de representación de datos: basados en microarrays y basados en imágenes médicas. Los resultados en su investigación indicaron al algoritmo SMO (Optimización mínima secuencial) como el candidato más potencial para ambos conjuntos de datos.

En otro trabajo para detección de cáncer de mama en sus primeras etapas Mookiah et al. [45] hacen uso de transformadas discretas wavelet (DWT) y características de textura

extraídas de termogramas en la clasificación de grupos normales y anormales. Distintos clasificadores como árboles de decisión (DT), clasificadores difusos, Bayes, K vecino más cercano, modelos Gaussianos mixtos y redes neuronales probabilísticas son ocupados. Los mejores resultados los obtuvieron con árboles de decisión y con los clasificadores difusos. Se han realizado más trabajos ocupando características de textura, otro de ellos es el de Pramanik et al. [50] desarrollaron una nueva técnica de extracción de características de textura local, denominada varianza de bloques (BV), para diferenciar los termogramas malignos de mama de los termogramas benignos de mama. La varianza del bloque (BV) utiliza la variación local de las intensidades para identificar la textura del contraste en la imagen termal del pecho de escala de grises. Haciendo uso de la simetría en la temperatura identifica la presencia de anomalías. Una red neuronal de retro propagación con una regla de gradiente descendiente se empleó en el entrenamiento para evaluar el desempeño de la clasificación. Sathish et al. [56], realizan el análisis de asimetría de temperatura de la imagen de un termograma de mama mediante el desarrollo de una segmentación totalmente automática de la mama derecha e izquierda. Para ello utiliza las características de forma de la mama y el ajuste de la curva polinomial. Adicionalmente extrae características de textura basadas en matriz de histograma y de co-ocurrencia de nivel de gris de las imágenes segmentadas. Para las pruebas ocupan un clasificador de máquinas de vectores de soporte con kernel RBF Mejía et al. [40] también hacen un análisis de texturas para identificar anomalías en los termogramas. Estas características que extrae las ocupa para alimentar un clasificador de vecinos más cercanos obteniendo resultados buenos.

Raghavendra et al. [52], proponen una técnica basada en el Histograma de Gradientes Orientados (HOG) localmente normalizados. HOG es capaz de registrar las variaciones internas de minutos en termogramas. Con el fin de reducir las dimensiones de los descriptores extraídos HOG, se utiliza una proyección para preservar la ubicación del kernel (KLPP). Las características KLPP resultantes se clasifican para determinar clases normales y malignas. También desarrolló un índice de Riesgo de Cáncer de Seno (BCRI) usando características significativas de KLPP que pueden discriminar las dos clases usando un único índice integrado.

Calderón et al. [15] consideran dos factores principales en su investigación: la base de datos para el diseño y el tipo de entradas utilizadas para los clasificadores. El modelo que propone se basa en un clasificador difuso utilizando características estadísticas. Los resultados del sistema CAD se compararon con el estado patológico de los tejidos de los pacientes y mostraron resultados satisfactorios que permitieron distinguir entre tejidos cancerosos y sanos.

Gogoi et al. [25] enfatizan su trabajo principalmente sobre la investigación de características estadísticas referentes a la simetría de la temperatura, que pueden diferenciar los termogramas sanos de mama de los patológicos. El análisis y los resultados experimentales tienen entre sus características estadísticas de primer orden, la diferencia media, asimetría, entropía y desviación estándar, estadísticas que demostraron ser las más eficientes en la detección de asimetría.

Gaber et al. [22] proponen un sistema CAD que clasifica los termogramas de cáncer de mama a normales y anormales. El enfoque que ocupó consta de dos fases principales: la

segmentación automática y la clasificación. Para la primera fase, se propuso un enfoque de segmentación mejorado basado tanto en conjuntos Neutrosóficos (NS) como en el algoritmo optimizado Fast-Fuzzy c-media (F-FCM). Además, se sugirió el proceso de post-segmentación para segmentar el parénquima de mama (región de interés) a partir de imágenes de termograma. Para la clasificación, se utilizaron diferentes funciones de kernel de las Máquinas de Vectores de Soporte (SVM) para clasificar el parénquima de mama en casos normales o anormales. Los resultados experimentales mostraron que en este trabajo alcanzaron una precisión bastante buena, haciéndolo una propuesta interesante.

Silva et al. [60] proponen una metodología híbrida para analizar termografía infrarroja dinámica para indicar a los pacientes con riesgo de cáncer de mama, utilizando el aprendizaje automático no supervisado y supervisado, técnicas que caracterizan la metodología como híbrida. En la ejecución de la termografía infrarroja dinámica, una secuencia de termogramas de mama se genera. En la metodología propuesta, esta secuencia se procesa y analiza por varias técnicas. En primer lugar, la región de los senos se segmenta y se registran los termogramas de la secuencia. A continuación, se construyen series temporales de temperatura y se aplica el algoritmo k-means en estas series usando varios valores de k. El agrupamiento formado por el algoritmo k-means, para cada valor de k se evalúa utilizando índices de validación de clusters, generando valores tratados como rasgos en la etapa de construcción del modelo de clasificación. Para la construcción del modelo de clasificación, una herramienta de minería de datos fue utilizado para resolver la selección de algoritmos combinados y la optimización de hiperparámetros (CASH) en las tareas de clasificación. Además del algoritmo de clasificación recomendado por la herramienta de minería de datos, clasificadores como redes neuronales o árbol de decisión se ocuparon en el conjunto de datos utilizado para la evaluación.

Sayed et al. [57] emplean técnicas de bio-inspiración de enjambre. Tales sistemas están constituidos por una población de agentes simples que interactúan localmente entre sí y con su entorno. El sistema se inicializa con una población de individuos (es decir, soluciones potenciales). Estos individuos son manipulados a lo largo de muchos pasos de iteración imitando el comportamiento social de insectos o animales, en un esfuerzo por encontrar la óptima en el espacio del problema. Una solución potencial se simplifica a través del espacio de búsqueda modificándose según su experiencia pasada y su relación con otros individuos en la población y el medio ambiente. Sayed presenta cuatro algoritmos de enjambres que incluyen Optimización de Enjambre de Partículas (PSO), Optimizador de Lobo Gris (GWO), Optimización de Llamada de Polilla (MFO) y Optimización de Algoritmo de Firefly (FA). El esquema ha sido ocupado para ver su capacidad y precisión para clasificar las imágenes de cáncer de mama en dos resultados: normales o no normales.

Resmini et al [53] se centran en la comparación de protocolos para la adquisición de datos utilizando una cámara infrarroja, pre procesamiento de los datos adquiridos (utilizando operaciones como región de interés o extracción de ROI, registro de imágenes y algunas otras operaciones para preparar las imágenes o matrices térmicas que se utilizarán en los cálculos), reconstrucción 3D y recomendaciones de diagnóstico de los datos de IR. Después de experimentos y comparaciones entre la diversidad de recomendaciones y formas de adquisición de datos

reportados en la literatura, Resmini propone un nuevo protocolo de captura y almacenamiento de datos IR.

La segmentación de la región de interés para cualquier sistema CAD es una parte muy importante de todo el proceso. Algunos trabajos hacen énfasis en esta etapa, por ejemplo, Ali et al. [9] proponen un método de segmentación automática para la Región de Interés (ROI) a partir de termogramas de mama. Este método se basa en el parámetro de protocolo de adquisición de datos (la distancia del paciente a la cámara) y las estadísticas de imagen de la base de datos DMR-IR. Para evaluar los resultados de este método, también se propuso un enfoque para la detección de anomalías mamarias de los termogramas. Se extrajeron características estadísticas y de textura del ROI segmentado y se utilizó SVM con su función de núcleo para detectar los senos normales y anormales basados en estas características. Los resultados experimentales fueron muy buenos, cercanos al 100 por ciento. Esto significa que el método de segmentación propuesto es una técnica prometedora para extraer el ROI de los termogramas de mama. Por otro lado Conci et al. [16] muestran por qué el estimador de distancia más utilizado (por ejemplo, la distancia de Hausdorff y las funciones de distancia orientada) no es adecuado para la aplicación biomédica. Conci presenta una nueva técnica para definir el grado de corrección de la región de interés que se desarrolló para servir de base para las comparaciones para validar trabajos sobre la segmentación de imágenes biomédicas. El método propuesto se aplica tanto a ejemplos de datos reales como simulados.

Finalmente Abdel-Nasser et al. [7] se centran en el área del pezón, ya que señala que es un hito anatómico importante en los termogramas. La ubicación del pezón es invaluable en el análisis de imágenes médicas porque puede ser utilizado en varias aplicaciones, como el registro de imágenes y la fusión de modalidades. Este artículo propone un método no supervisado, automático, preciso, simple y rápido para detectar pezones en termogramas. Las principales etapas del método propuesto son: segmentación del cuerpo humano, determinación de los candidatos a los pezones utilizando umbrales adaptativos y detección de los pezones utilizando un nuevo algoritmo de selección.

Este trabajo busca centrarse en un nuevo método de extracción de características que permita clasificar correctamente las imágenes de los termogramas de mama, ya sea que existan anomalías o que no las existan.

El trabajo se centra en la fase de la extracción de características por lo cual se necesita estudiar y evaluar las principales características que se han considerado en trabajos similares. Para el análisis se considera principalmente trabajos que ocupan la base seleccionada [59]. Por ejemplo Gogoi et al. [25] ocupan características de primer orden con base en los valores de intensidad de la imagen, a partir del histograma calculan algunos valores estadísticos como la media, desviación estándar, mediana o diferencias máximas de intensidad entre cada pecho solo por mencionar algunas. Mohammed et al. [44] también hace uso de características de primer orden, dichas características son la media, la varianza, la asimetría y la curtosis, aunque estas características se extraen en base a los momentos de color para cada canal, por lo que si se trabaja la imagen en RGB, se tendrán 12 características de primer orden. Adicionalmente también extra información en base a la textura, para ello ocupa la matriz de co-ocurrencia de niveles de grises en cuatro direcciones.

Calderón et al. [15] ocuparon 8 características de primer orden sobre los valores de la intensidad de la imagen, entre ellas están la media, desviación estándar, moda, mediana, temperatura máxima, donde esta temperatura se mide en base a que tanta intensidad tiene la imagen en una zona, y también considera la asimetría de valores en cada pecho.

Ali et al. [9] presentaron características de primer orden y de textura, en las primeras ocupan la media, desviación estándar, asimetría y curtosis entre otras, estos valores se calculan sobre la intensidad de los valores en la imagen, en los de textura se calcula la energía, contraste, homogeneidad por mencionar algunas, todo esto calculado a partir de la matriz de co-ocurrencia de niveles de grises.

Mejía et al. [40] consideran en su trabajo solo características de primer orden ocupando los valores de intensidad de la imagen, estas son la media, mediana, moda, máximo, mínimo, varianza, desviación estándar, coeficiente asimétrico y la curtosis. En otro trabajo Gaber et al. [22] se centran más en características de textura extraídas de la matriz de co-ocurrencia de niveles de grises aunque también ocupa algunas de primer orden incorporando coeficientes absolutos de Gabor.

Pramanik et al. [50] dividen el área de interés en ocho clases distintas y para cada clase encuentran características de textura únicamente, entre ellas está la asimetría, la curtosis y la media. Sathish et al. [56] proponen características de primer orden con base en las intensidades de la imagen y de textura basadas en la matriz de co-ocurrencia. Algunas características son media, varianza, asimetría, curtosis, entropía y homogeneidad.

En otro trabajo de Pramanik et al. [51] dividen la imagen en lo que llaman clusters, la imagen se particiona en 5 regiones y de cada región se extraen características de primer orden, como la desviación estándar, asimetría y curtosis, esto para cada canal en la representación de la imagen RGB.

Silva et al. [60] ocupa k-means con distintos valores de k para generar distintos cluster, para cada uno de ellos ocupa distintas series de tiempo de temperaturas como características a extraer. Sayed et al. [57] ocupan características de textura, de primer orden y también consideran coeficientes absolutos de Gabor extraídos de la onda de Gabor. En Lessa et al. [37] también se centran en las características de primer orden con base en las intensidades de la imagen, los valores que consideran son la media, varianza, desviación estándar, asimetría, curtosis, entropía, rango y mediana. Raghavendra et al. [52] proponen extraer descriptores basados en el histograma del gradiente de orientación.

3.2. Análisis de Trabajos

De todos los trabajos se desprenden dos grandes grupos de características, las de primer orden, en su mayor parte con base en las intensidades de los valores de la imagen y los de textura en su mayor parte extraídas de la matriz de co-ocurrencia de niveles de grises. El Cuadro 3.1 resume este análisis.

Las características de primer orden fueron las más ocupadas por los autores descritos y una tendencia también alta fue extraer características de primer orden a la par de algunas de

textura para hacer más robusto el vector de características para la etapa de los experimentos. Por tal razón en este trabajo se hace la propuesta de hacer extracción de características de primer orden y con base en la textura.

| Grupo de Características | Autores | Principales Características |
|--------------------------|--|--|
| Primer Orden | Gogoi et al. [25], Mohammed et al. [44], Calderon et al. [15], Ali et al. [9], Mejia et al. [40], Gaber et al. [22], Sathish et al. [56], Pramanik et al. [51], Sayed et al. [57], Lessa et al. [37] | Media, Mediana, Moda, Desviación Estándar, Varianza, Asimetría, Curtosis, Entropía |
| Textura | Mohammed et al. [44], Ali et al. [9], Gaber et al. [22], Pramanik et al. [50], Sathish et al. [56], Sayed et al. [57] | Energía, Entropía, Correlación, Contraste, Homogeneidad |
| Otras | Silva et al. [60], Raghavendra et al. [52] | Series de tiempo de temperaturas, Descriptores basados en el histograma del Gradiente de orientación |

Cuadro 3.1 – Análisis de las características extraídas de la región de interés

4 Metodología

En este capítulo se presenta la descripción del método propuesto para el procesamiento de las imágenes térmicas en un ámbito médico, en particular con termografías de seno. Esta sección describe cada una de las fases que comprende el proceso, como lo son la adquisición de las imágenes, selección de imágenes, pre-procesamiento de imágenes, segmentación de la región de la interés, extracción de características, selección de características y clasificación de las imágenes

4.1. Adquisición de imágenes

La base de datos de termogramas DMR-IR[59], fue adquirida por la Universidad Federal de Fluminense en el Hospital Universitario Antonio Pedro (HUAP). La base se compone de imágenes térmicas, matrices de temperatura asociadas a cada imagen así como de información relevante para el especialista de cada paciente. La adquisición y el uso de las imágenes fueron autorizados por el Comité Ético del HUAP y registrado en el Ministerio Brasileño de Salud.

Las imágenes fueron capturadas por una cámara térmica FLIR, modelo SC620, que tiene un rango de sensibilidad de menos de 0.04°C y un captura estándar de -40°C a 500°C . Las imágenes tienen una dimensión de 640×480 píxeles. Todas las imágenes vienen en un formato RGB y las matrices de temperatura vienen en archivos de texto, donde los datos de las temperaturas vienen en una posición matricial y cada valor corresponde al pixel asociado a la misma posición.

Para cada paciente se adquirió su información mediante dos protocolos distintos:

- Dinámico. En este se capturaron 20 imágenes durante 5 minutos con un procesamiento de las imágenes descrito en [59]
- Estático. Para este caso se dejó reposar a los pacientes por 10 minutos. Para este protocolo se tomaron cinco imágenes (una frontal, dos laterales de lado izquierdo a 45° y 90° y dos laterales de lado derecho a 45° y 90°)

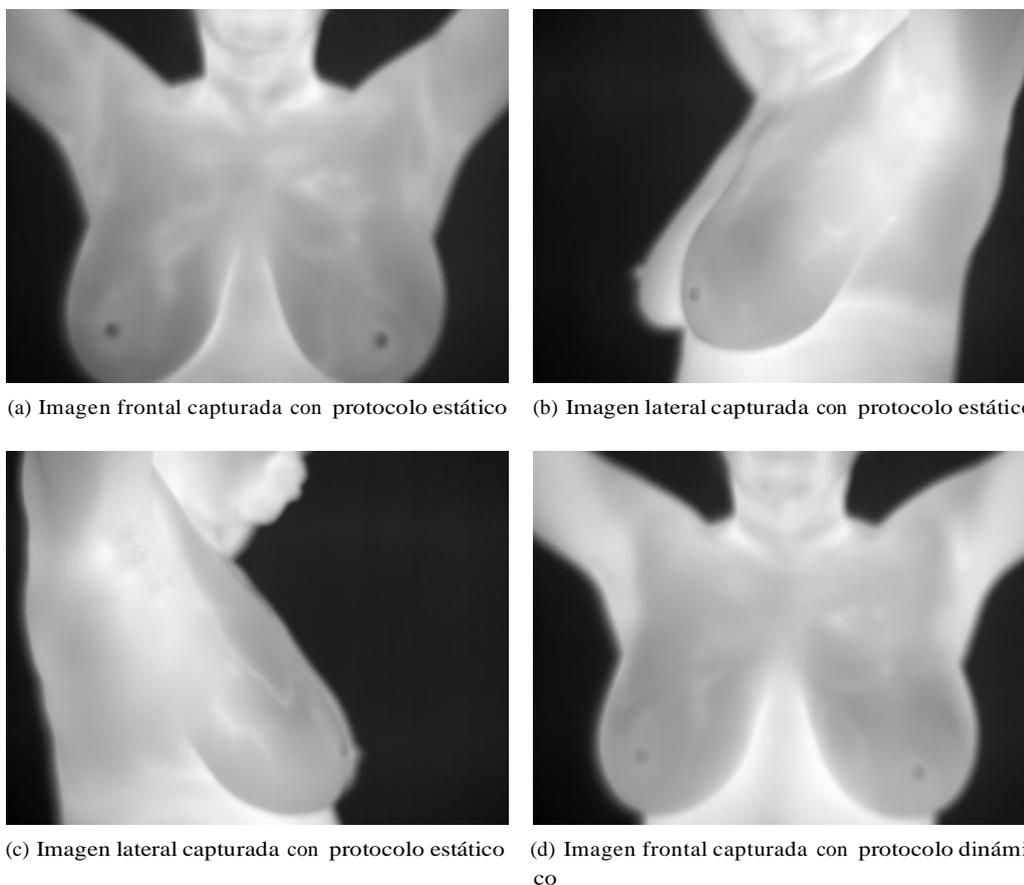


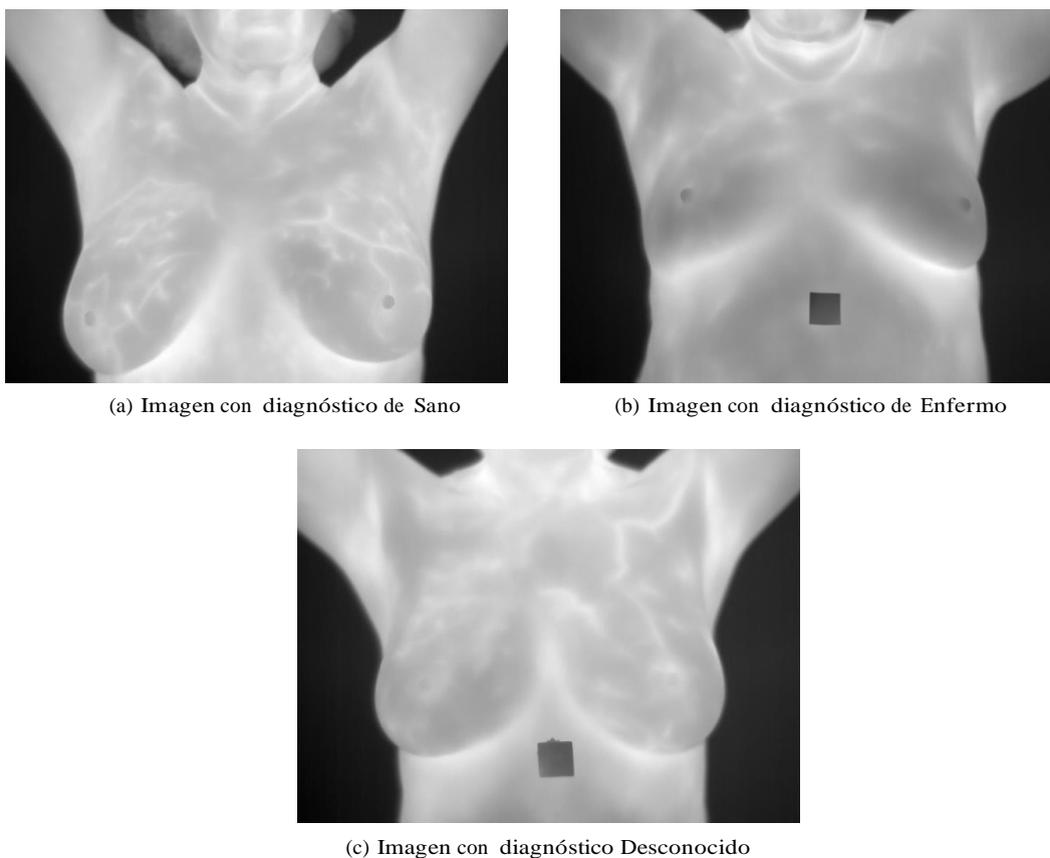
Figura 4.1 – Ejemplos de imágenes de la base de datos

Algunos ejemplos de las imágenes que se encuentran en la base de datos se muestran en la Figura 4.1. Las imágenes de los pacientes ya vienen asociadas a un diagnóstico, las clases que se consideran son las de Sano, Enfermo y Desconocido. Algunos ejemplos de cada clase se muestran en la Figura 4.2

4.2. Selección de imágenes

En esta tesis se busca diseñar un método de extracción de características a partir de una imagen térmica con el propósito de que estas sirvan para poder detectar anomalías relacionadas con el padecimiento de cáncer de seno. Teniendo esta finalidad es necesario realizar una depuración y análisis previo de todas las imágenes para eliminar cualquier fuente

de información que pueda introducir ruido, para ello se realizaron las acciones de depuración de base de datos y selección de imágenes, estas acciones se describen a continuación.



(a) Imagen con diagnóstico de Sano

(b) Imagen con diagnóstico de Enfermo

(c) Imagen con diagnóstico Desconocido

Figura 4.2 – Ejemplos de distintas clases de imágenes

4.2.1. Depuración de base de datos

La base de datos tiene registros de 287 pacientes, de estos registros únicamente 220 tienen imágenes térmicas asociadas, en los demás sólo se cuenta con información relacionada al diagnóstico, por lo que todos estos registros no se tomaron en cuenta. De los 220 registros restantes se analizó la calidad de las imágenes y después de hacer el análisis se encontraron 13 registros donde el formato de las imágenes que viene en escala de Grises no se correspondía o la calidad de las imágenes no era adecuada pues se había capturado de forma errónea, por ellos estos registros tampoco se tomaron en cuenta. Al final quedaron 207 registros de pacientes que se tomaron en cuenta. La Figura 4.3 muestra algunos ejemplos de los problemas detectados en la depuración.

4.2.2. Imágenes a ocupar

Una vez depurada la base de datos, se hizo un análisis respecto a qué imágenes ocupar. En primera instancia las imágenes laterales fueron descartadas pues para el proceso de segmentación y clasificación no contribuían con información de ambos senos de forma clara.

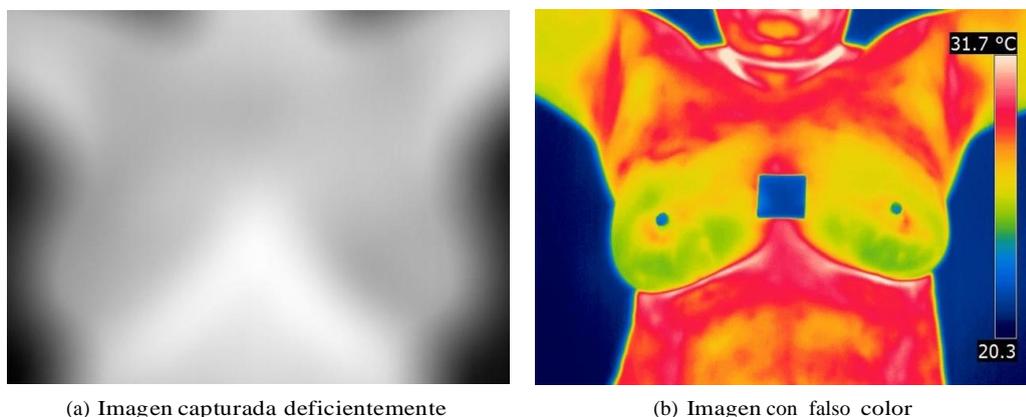


Figura 4.3 – Ejemplo de imágenes deficientes

| Registros de Pacientes | |
|---|------------|
| Originales | 287 |
| Sin Imágenes | 67 |
| Imágenes con Mala Calidad o Mal Formato | 13 |
| Total Imágenes a Ocupar | 207 |

Cuadro 4.1 – Resumen de depuración de registros

Al quedar únicamente imágenes frontales, se analizó con qué protocolo de adquisición trabajar y se encontró que en algunos registros no se tenían imágenes frontales con el protocolo dinámico, además de que al hacer una captura en ráfaga de varias imágenes con dicho protocolo se tendría que elaborar alguna técnica para seleccionar la mejor imagen o en su caso tomar todas las imágenes, situación que podría elevar la complejidad del trabajo, por esta razón se eligió trabajar con las imágenes frontales adquiridas con el protocolo estático. El Cuadro 4.1 muestra el resumen en el proceso de la depuración y selección de imágenes.

4.3. Pre-procesamiento de imágenes

Previo a la segmentación de la región de interés hay que realizar un procesamiento que ayude a preparar las imágenes de forma que el método de segmentación pueda funcionar correctamente, en este apartado se realizan dos acciones, la conversión de la imagen a escala de grises y la segmentación del fondo de la imagen.

4.3.1. Conversión a Escala de Grises

Las imágenes de la base de datos vienen en un formato RGB, sin embargo en cada uno de los canales la información es la misma en escala de grises. Dada esta situación si se considera solo un canal o se obtiene una imagen en escala de grises, no habría pérdida de

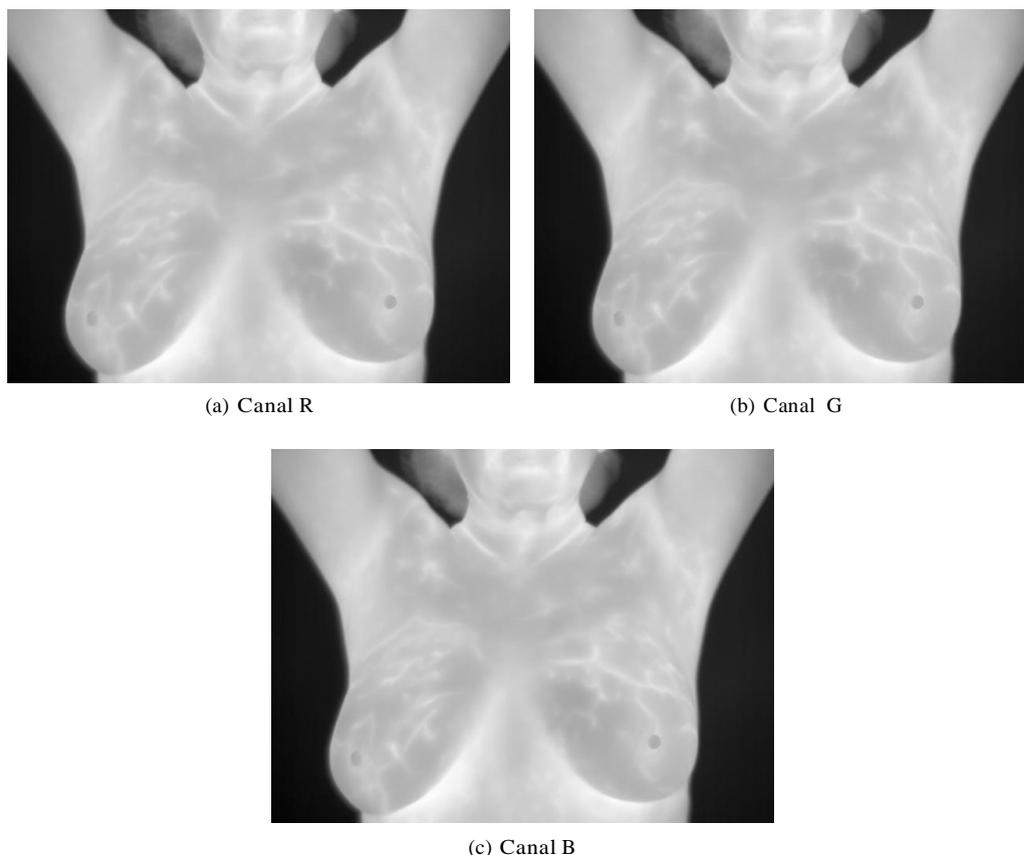


Figura 4.4 – Descomposición en cada canal de imagen RGB

información, es por ello que se opta por elegir la información en un solo canal para futuras operaciones ya que es más sencillo trabajar en un solo canal. La Figura 4.4 muestra como la información de cada canal es la misma.

4.3.2. Segmentación de fondo

Es necesario segmentar el cuerpo del fondo de alguna forma ya que así el análisis se podrá hacer solo sobre la región del cuerpo, así que tomando en cuenta las características de la imagen, donde el cuerpo se compone de colores grisáceos y el fondo en color negro, se implementa una segmentación basada en la intensidad de los colores presentes en la imagen. La Figura 4.5 muestra el histograma de la imagen, donde se aprecia un contraste claro entre los colores más oscuros (pertenecientes al fondo de la imagen) y los colores más claros (pertenecientes al cuerpo). Con ello se forman dos regiones en el histograma y un valle entre ellas. Para poder separar ambas regiones se utiliza el método de umbralización de Otsu [49], que encuentra el mejor valor de umbral que separa ambas regiones.

Con el valor encontrado, se realiza una operación de binarización, donde aquellos

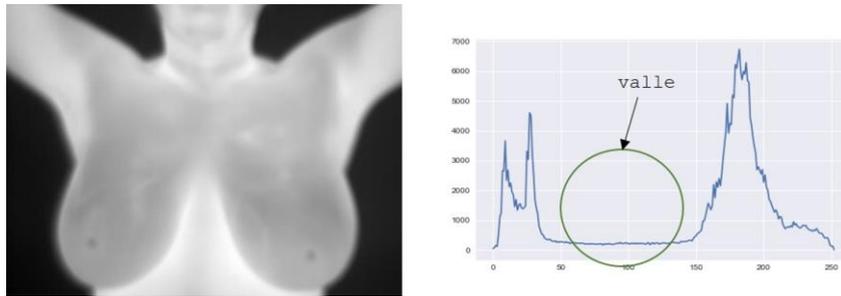


Figura 4.5 – Histograma de imagen mostrando valle entre valores

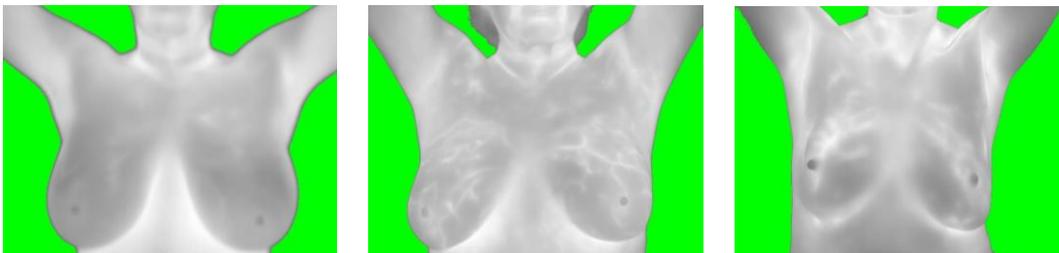


Figura 4.6 – Resultado de segmentación de fondo

valores iguales o por debajo de este umbral son establecidos en un color de control, que permite delimitar el fondo de forma controlada, en este caso se eligió el color verde, los valores mayores al umbral se dejan de forma idéntica a los originales. La ecuación 4.1 define la regla descrita.

$$f_{th}(x) = \begin{cases} cc & \text{if } x \leq th \\ x & \text{if } x > th \end{cases} \quad (4.1)$$

En la Figura 4.6 se muestran algunos resultados después de este proceso, en estos se puede apreciar como el procedimiento separa correctamente el fondo de la región del cuerpo.

4.4. Segmentación de ROI

Para la siguiente etapa hay que segmentar la región de interés (ROI), ante tal problemática se propone un método de segmentación automático. Para realizar una segmentación adecuada del ROI, primero hay que identificar los límites tanto superior como inferior de la región de interés. Cada tarea se analiza de forma independiente a continuación.

4.4.1. Identificación de límite inferior de la ROI

Esta etapa en particular es compleja debido a la ausencia de límites claros, esto en gran parte a la gran variedad de formas y tamaños que tienen los senos de una persona. El

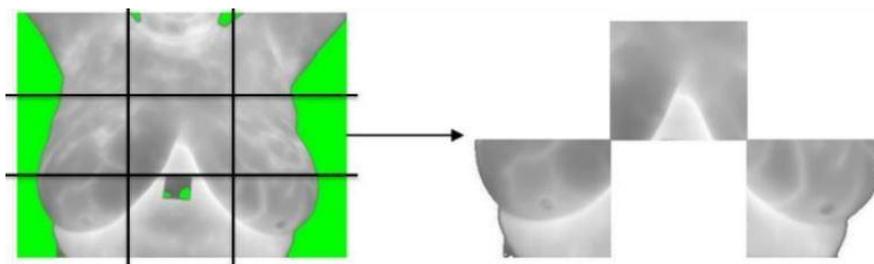


Figura 4.7 – Imagen dividida en sub regiones y sub imágenes seleccionadas

método en este apartado se va a basar en un análisis local de la imagen, buscando patrones en la variación de intensidad de color. Se buscan estas variaciones dado que en las imágenes térmicas los colores más oscuros están relacionados con temperaturas bajas y los colores más claros están relacionados con temperaturas altas. En las zonas del cuerpo que abarcan las imágenes las regiones que tienen las temperaturas más altas son en la axila, cuello y debajo de los pechos, donde esta última región es la de mayor extensión, factor relevante que se tiene en consideración. Por lo tanto ubicar estas zonas es el primer paso, para ello hay que identificar las regiones con los colores más claros.

Para enfrentar este problema la imagen se divide en tres sub regiones de arriba hacia abajo y en otras tres regiones de izquierda a derecha, al final la imagen ha sido dividida en nueve sub regiones. No todas las sub regiones aportan información útil para identificar el límite inferior de la ROI, por ello sólo se analizarán las siguientes regiones, la que se encuentra en la segunda fila y en la segunda columna, y las que están en la izquierda y derecha en la última. En estas sub regiones se encuentra la información más relevante para esta etapa en la mayoría de

las imágenes. Las sub regiones que se obtienen al dividir la imagen así como las que se escogen para el análisis posterior se muestran en la Figura 4.7

En cada una de las sub imágenes escogidas se aplica una mejora de contraste acumulativa [13] con el propósito de que los colores más claros se separen de los colores oscuros ya que como se explicó es importante descartar los valores oscuros que están relacionados con temperaturas bajas. El resultado se puede apreciar en la Figura 4.8. Con el objetivo de ir descartando estos valores es necesario encontrar un umbral entre valores claros y oscuros, así que el próximo paso es aplicar el método de Otsu [49]. Cualquier valor por encima de este umbral encontrado es segmentado.

En este momento se han removido varios valores oscuros y sin estos valores, en la imagen segmentada se realiza un proceso similar al descrito hasta el momento, es decir como primer paso se aplica nuevamente una mejora de contraste acumulativa, al existir menos información, el resultado deja en claro como los valores más claros se han separado mucho más de los valores oscuros en la imagen segmentada. Esto se puede apreciar en la Figura 4.9.

Existiendo una diferencia más clara entre valores claros y oscuros, se aplica nuevamente el método de Otsu para obtener el valor de umbral que divida ambos tipos de valores. Este umbral se almacena en una lista. El procedimiento se repite para las otras dos sub regiones, al

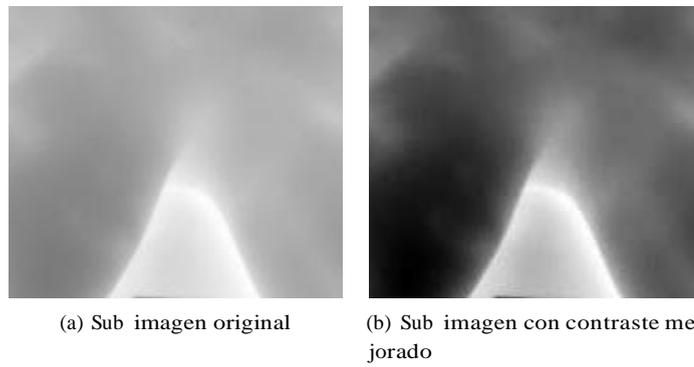


Figura 4.8 – Proceso de mejora de contraste de sub imagen

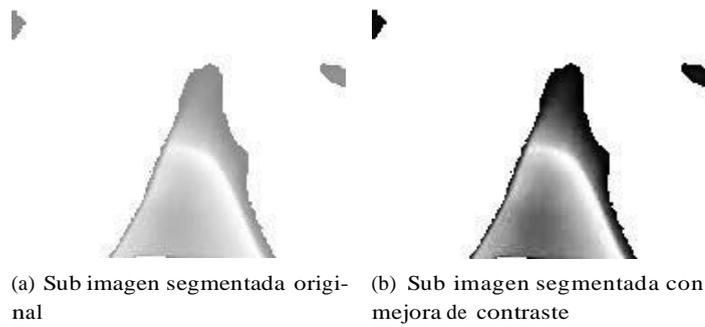


Figura 4.9 – Proceso de mejora de contraste de sub imagen segmentada

final hay una lista con tres valores de umbral locales, se calcula la media de todos los valores y ese valor se toma como el valor de umbral global. Con el umbral global, se binariza la imagen, el resultado se muestra en la Figura 4.10 donde se puede apreciar que se ha logrado el resultado que se buscaba, segmentar las regiones relacionadas con las temperaturas más altas.

Al buscar el límite inferior de la ROI en este apartado, cualquier conjunto de valores en color blanco por arriba de la mitad de la imagen, se descartan por lo que se establecen en color negro. Con la información restante se hace un análisis por densidad, así que se forman grupos de valores de color blancos que son vecinos, un grupo es una lista que se componen de todos los puntos que pertenecen a esa misma región. Todos los grupos se almacenan en otra lista y se ordenan del grupo con más elementos al de menor tamaño. El método está interesado en encontrar la región de más tamaño, pues como se describió es la referente al límite inferior, sin embargo en ocasiones no se forma una única región donde se concentran las temperaturas altas por debajo de los pechos, sino que se forman dos regiones de tamaño considerable, una por debajo de cada pecho, así que se realiza una verificación, si la proporción del segundo grupo con más elementos es al menos de 34% (este valor se encontro haciendo pruebas a lo largo de todas las imágenes) con respecto al grupo con más elementos, entonces este segundo grupo también se considera parte del límite, de no ser así, sólo se considera el primero y para



Figura 4.10 – Imagen binarizada con umbral encontrado automáticamente



Figura 4.11 – Imagen después de aplicar análisis por densidad de regiones

el resto de los grupos, a cada uno de los puntos que los componen se establecen sus valores en negro en la imagen, el resultado se visualiza en la Figura 4.11.

Una vez que ya se tiene identificada la región del límite inferior, se realizan un par de operaciones más, primero se realiza un adelgazamiento de la región, para ello se checa en cada columna de la imagen de arriba hacia abajo cuando se encuentra el primer pixel en blanco, este valor se mantiene y cualquier otro valor por debajo de este sobre la misma columna se establece en negro. Con el límite adelgazado se aplica el método de interpolación cúbica de Lagrange tomando cuatro puntos de cada curva, uno por cada extremo y dos cercanos a cada extremo. El método define los coeficientes del polinomio de tercer grado de cada curva y con ambos polinomios se obtiene el punto de intersección, solo se igualan ambos polinomios a cero y se resuelve la ecuación y se analizan las soluciones reales para definir el punto de intersección. El resultado se muestra en la Figura 4.12

4.4.2. Identificación de límite superior de la ROI

Con el límite inferior identificado ahora se necesita identificar el límite superior, para ello se realizan un conjunto de operaciones estadísticas. Se observa en el conjunto de imágenes de la base de datos que gracias al protocolo de adquisición de las imágenes todos los pacientes tienen que tener levantados sus brazos quedando casi en línea recta con los bordes laterales del

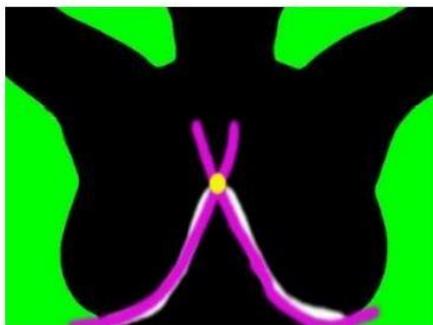
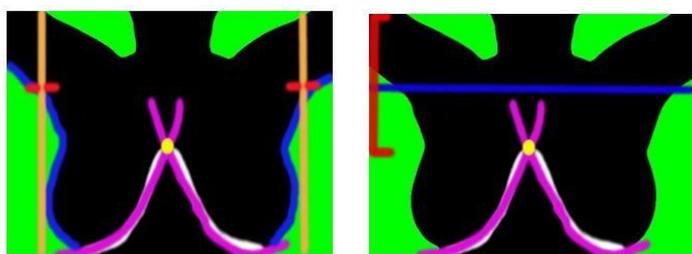


Figura 4.12 – Límite inferior definido así como punto de intersección



(a) En azul, region de puntos de transición, en naranja zona aproximada de la media de los valores de las coordenadas x, en rojo zona aproximada de la desviación estándar
 (b) En rojo zona de validación para coordenada y de punto que se selecciona, en azul límite superior encontrado

Figura 4.13 – Identificación de límite superior de ROI

cuerpo, esta información se toma en cuenta para la propuesta de esta sección. Las coordenadas en los ejes x y y donde existe una transición del color de control al cuerpo se guardan en una lista, una lista por cada lado del cuerpo. Estos puntos se guardan de la parte baja de la imagen hacia arriba, siendo los primeros registros cercanos a la zona de los pechos y los últimos en la zona de los brazos. Los puntos que existen de la parte baja de la imagen hasta la zona de la axila tienen coordenadas similares, solo en la parte de los brazos empiezan a variar y justo en estos puntos es donde se pueden establecer el límite superior de la ROI.

Ocupando la lista de puntos de transición, se calcula la media y la desviación estándar de las coordenadas x, con estos valores se chequea sobre la lista cuál es el primer punto en su coordenada x que es mayor a la media calculada más/menos (dependiendo del lado de cuerpo que se analice) la desviación estándar, este punto se almacena. Después de realizar este procedimiento por cada lado del cuerpo, se tienen dos valores, se toma el valor con la

coordenada y con el valor más grande siempre y cuando este valor sea menor a la coordenada y del punto de intersección encontrado en la fase previa. El resultado se muestra en la Figura 4.13

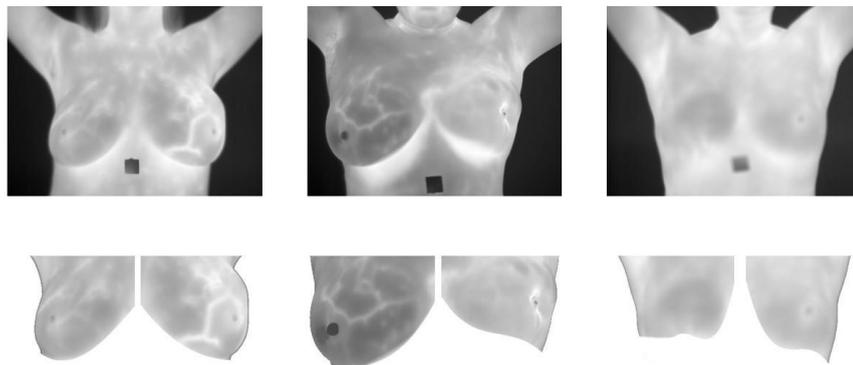


Figura 4.14 – Resultados del método de segmentación automática de la ROI

4.4.3. Segmentación de la ROI

Finalmente se hace la segmentación de la ROI con la información obtenida, se ocupan los límites inferiores y superiores, en los límites laterales se ocupa el color de control de la segmentación del fondo, toda región que contenga este color de control será removida, por último se toma el punto de intersección entre ambos pechos para generar una imagen por cada pecho. Algunos resultados se muestran en la Figura 4.14. Los resultados cuantitativos de la aplicación del método propuesto sobre la base de datos se describen en el siguiente capítulo.

4.5. Extracción de Características

Esta tesis busca proponer un conjunto de características que sean lo suficientemente descriptivas para después ser usadas en tareas de clasificación con aprendizaje automático. El enfoque que se ocupa en el análisis de termogramas es la búsqueda de asimetrías entre los senos, una persona sana tiene una distribución homogénea en los niveles de intensidad de su termograma, concepto relacionado con la simetría de temperatura que hay en el cuerpo humano, mientras que una persona enferma tiene niveles de intensidad menos homogéneos.

Estas características se agrupan en un vector que son la entrada del método de aprendizaje automático. Para la generación de estos vectores, se propone analizar la ROI con base en 2 tipos de características:

- Características de primer orden
- Características de segundo orden

Después de hacer el análisis del estado del arte e identificar las principales características extraídas, en este trabajo se propone la extracción de las siguientes características:

4.5.1. Características de Primer Orden

En las características de primer orden se busca la simetría de valores entre los senos través de operadores estadísticos aplicados, estas características buscan patrones en el conjunto de datos. Las características propuestas de este tipo son las siguientes:

- **Media.**
- **Mediana**
- **Desviación Estándar.**
- **Curtosis.**
- **Máximo.**
- **Mínimo.**
- **Asimetría.**
- **Entropía.**
- **Energía.**

Estas características se extraen de dos fuentes de información, del histograma normalizado de cada imagen y de la matriz de temperaturas asociadas a cada imagen, cabe hacer la mención que para la matriz de temperaturas también se hace una segmentación sobre la matriz original, en el momento que se hace la segmentación de cada pecho, al mismo tiempo se genera una nueva matriz de temperaturas conservando los valores presentes en la imagen segmentada del ROI.

4.5.2. Características de Segundo Orden

Las características de textura de segundo orden son usadas para verificar la similaridad entre los pechos teniendo en cuenta la interrelación entre los valores del conjunto de datos, en este caso se traslada en una distribución homogénea de los niveles de intensidad por lo que sus características de textura deben de ser similares o presentar diferencias cuando existan anomalías. Las características propuestas de este tipo son las siguientes:

- **Homogeneidad.**
- **Entropía**

- **Contraste.**
- **Correlación.**

| Vector | Características | Total de Características |
|----------|--|--------------------------|
| Vector-1 | Primer Orden con base a Histograma y Matriz de Temperaturas | 36 |
| Vector-2 | Primer Orden con base a Histograma | 18 |
| Vector-3 | Primer Orden con base a Matriz de Temperaturas | 18 |
| Vector-4 | Primer Orden con base a Histograma y Textura | 28 |
| Vector-5 | Primer Orden con base a Matriz de Temperatura y Textura | 28 |
| Vector-6 | Primer Orden con base a Histograma y Matriz de Temperatura y Textura | 46 |
| Vector-7 | Textura | 10 |

Cuadro 4.2 – Vectores de Características propuestos

- **Energía.**

Estas características se extraen de la matriz de co-ocurrencia de niveles de grises que se genera a partir de la imagen de cada pecho.

4.5.3. Vectores de Características generados

Se tiene un total de 14 características propuestas de un total de 3 fuentes de datos distintas (Histograma de imagen, matriz de temperaturas asociadas a una imagen, matriz de co-ocurrencia de niveles de grises), recordando que se tienen dos imágenes por paciente, una de cada pecho dando un doble de características extraídas en cada vector. Se propone la creación de siete vectores de características combinando las características y las fuentes de datos. Los vectores generados se resumen en el Cuadro 4.2.

4.6. Balanceo de la base de datos

La base de datos con la que se trabaja se compone de dos clases, la distribución de las imágenes que se ocupan y el total de cada clase se lista en el Cuadro 4.3. Como se observa la clase de Sano tiene un 65 % de instancias del totalidad de imágenes, una diferencia considerable respecto a la clase de Enfermo, se tiene una base desbalanceada y al tener una base de este tipo, los resultados del entrenamiento en la fase de clasificación pueden sobreajustarse y

tender hacia la clase de Sano y no generalizar bien las características de ambas clases. Ante el problema descrito se propone un balanceo estocástico para que el número de instancias a considerar en cada experimento realizado esté balanceado en cuanto a clases. En el siguiente capítulo se detalla el método de balanceo y la elaboración de los experimentos.

| Clase | Número de Instancias | Porcentaje |
|---------|----------------------|------------|
| Sano | 165 | 79.71 % |
| Enfermo | 42 | 20.29 % |
| Total | 207 | 100 % |

Cuadro 4.3 – Distribución de clases de imágenes en base de datos

4.7. Clasificación de Imágenes ocupando una Red Neuronal

Una vez que se tienen los vectores de características se tiene que validar que tan buenas son estas, así que un proceso de clasificación de imágenes con base en las características extraídas se aborda en esta sección. El proceso de clasificación se hace a través de un método de aprendizaje supervisado como lo es una Red Neuronal Artificial.

Existen distintas técnicas de aprendizaje supervisado, se ha decidido ocupar una red neuronal con una función de activación sigmoideal que es eficiente en problemas de clasificación binaria (es decir tener dos clases a clasificar). Esta red se compone de una capa de entrada que tiene como número de neuronas el número de características que tenga el vector que se ocupe, una capa oculta y la capa de salida, que para el problema tiene dos neuronas, una por cada clase que busca identificarse, la de Sano y la de Enfermo. Se considera el problema como uno de clasificación porque en cada vector de características cada instancia esta etiquetada con la clase a la cual corresponde dicha información.

4.7.1. Normalización de atributos

Las redes neuronales son muy sensibles a conjuntos de datos numéricos donde los valores difieran mucho entre ellos, es por ello que para evitar que la red se vea influenciada por esta problemática se realiza una normalización de atributos. Existen varios métodos de normalización, el ocupado en esta tesis es el de Min-Max que retornará todos los valores en el rango de [0-1].

4.7.2. Selección de Características

En el proceso de aprendizaje se da el caso de que muchas características sean redundantes o que no provean información relevante, por lo que estas características se pueden descartar sin que haya pérdida de información. La selección de características resuelve este problema a través de distintos métodos. La aplicación de una de estas técnicas hace que el proceso de aprendizaje sea más rápido pues hay menos información que procesar, puede que

sea más fiable, pues sólo se conservan los atributos más relevantes y ello puede influir en el proceso de entrenamiento a que sea más general y que no haya un sobreajuste.

El método que se aplica en este trabajo es el de Selección de Subconjuntos de Características basada en Correlaciones [26] en combinación con una de selección de los 10 mejores atributos de acuerdo a los valores obtenidos por el método de selección.

4.7.3. Búsqueda mejores hiperparámetros

Además de la función de activación y el número de capas ocultas así como el número de neuronas en estas, hay otros hiperparámetros que deben de ajustarse en una red neuronal como el momentum, la tasa de aprendizaje, el tiempo de entrenamiento. El correcto ajuste de estos hiperparámetros para cada conjunto de datos que se ocupe es fundamental para tener una precisión mayor. En el siguiente capítulo se describe el proceso para la búsqueda y selección de estos atributos y los resultados encontrados.

4.7.4. Validación

Finalmente ya con el debido pre procesamiento de los datos y el ajuste de hiperparámetros se realiza el proceso de validación del proceso de entrenamiento, existen diversas técnicas de validación, en esta tesis se realizó una validación cruzada con un análisis de resultados con diversas métricas como la precisión, la razón de falsos positivos y verdaderos negativos, así como con la ilustración de la validación por medio de matrices de confusión. Los resultados y detalles se listan en el siguiente capítulo.

4.8. Diagrama general de la Metodología

En la Figura 4.15 se muestra el diagrama general de la metodología que se ha descrito.

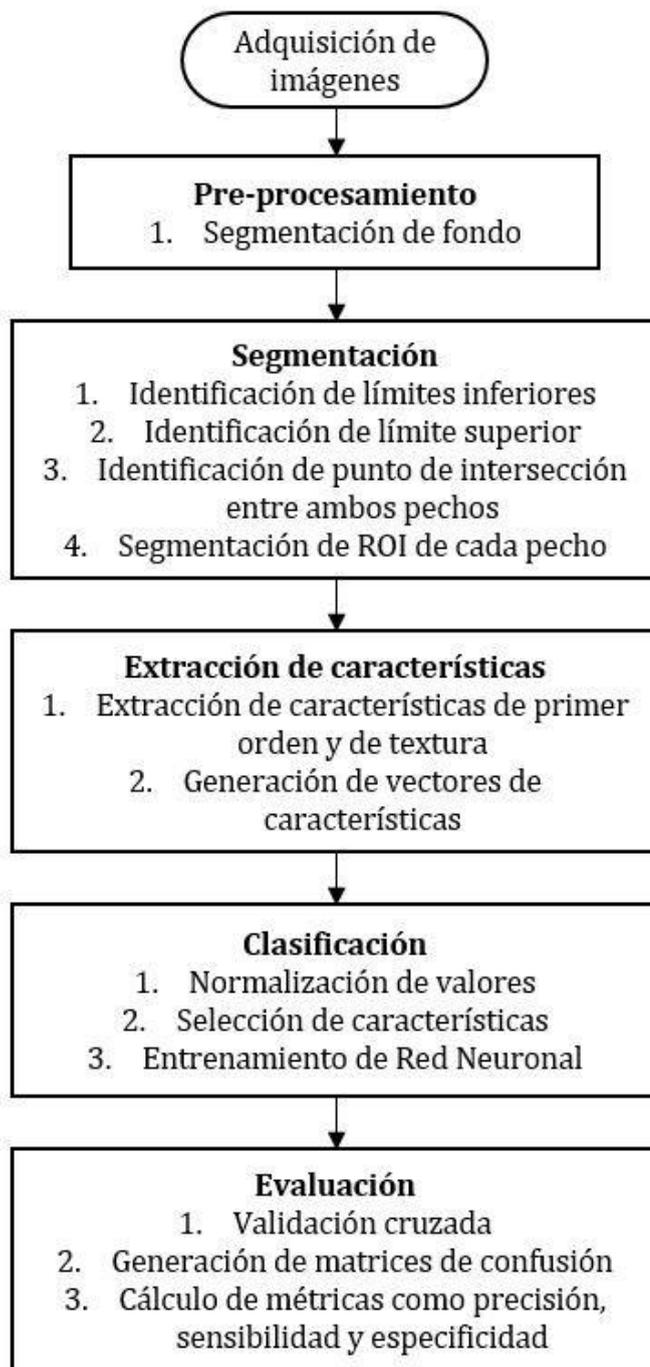


Figura 4.15 – Diagrama general de la metodología

5 Resultados

En esta sección se presentan los resultados obtenidos de la metodología utilizada. La primera sección de este capítulo muestra los resultados de la detección automática del ROI (área de mama) con el algoritmo propuesto, la segunda sección de este capítulo muestra los resultados del reconocimiento de patrones ocupando la red neuronal artificial descrita para la clasificación y los vectores de características generados. La última parte de este capítulo presenta el análisis de los resultados.

5.1. Resultados Segmentación

El método de segmentación propuesto se aplicó a las 207 imágenes de la base de datos [59] que ya han sido depuradas. La técnica funcionó en la mayoría de las imágenes pero hubo un conjunto de imágenes que presentaron problemas y en las cuales el proceso no se pudo culminar, así a forma de resumen primero se hace un recuento en el Cuadro 5.1 donde se muestra de la totalidad de las imágenes en las cuales el método termino de ejecutarse y devolvió algún resultado. La Figura 5.1 muestra una imagen y el resultado obtenido con el método de segmentación automática. Dentro de las imágenes que se pudieron procesar hay distintos resultados, que se han categorizado como Buenos, Aceptables y Malos. A un resultado bueno se le considera a cualquier salida del método de segmentación que de una aproximación bastante exacta de la región de interés, a un resultado Aceptable se le considera a cualquier salida que no afecte la región de interés pero que tal vez regrese información extra en la imagen y finalmente a un resultado Malo se le considera a cualquier salida que afecta la región de interés, es decir que segmenta datos del ROI y donde se asume que hay

| Resultado | Imágenes | Porcentaje |
|----------------------|----------|------------|
| Ejecución Completa | 175 | 84.5 % |
| Ejecución Incompleta | 32 | 15.5 % |
| Total | 207 | 100 % |

Cuadro 5.1 – Rendimiento de método funcionamiento de segmentación automática en base de datos

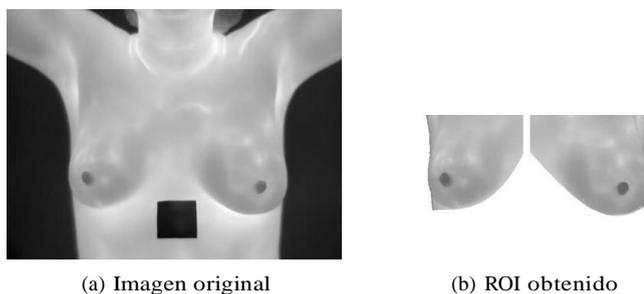


Figura 5.1 – Resultado obtenido con método de segmentación automática

| Categoría | Imágenes | Porcentaje |
|------------|----------|------------|
| Buenos | 140 | 80 % |
| Aceptables | 20 | 11.42 % |
| Malos | 15 | 8.58 % |
| Total | 175 | 100 % |

Cuadro 5.2 – Resumen por categoría de segmentación

pérdida de información relevante. En la Figura 5.2 se muestra un ejemplo de cada resultado y el Cuadro 5.2 resume los resultados de cada categoría descrita de las imágenes procesadas. Con el fin de cuantificar el resultado de las imágenes que se han segmentado, se realiza una comparación con un conjunto de imágenes base que han sido segmentadas manualmente. Una vez que se tienen los dos conjuntos de datos se realizó una comparación entre ellos. Para ello se toma la imagen segmentada manualmente y se calcula la relación de diferencia con la imagen segmentada automáticamente como porcentaje. Por último se hace el cálculo de la media de la suma de todos los porcentajes y se toma como medida de precisión global. El resultado obtenido fue de un 94%. La Figura 5.3 muestra ejemplos de resultados con la técnica y en comparación con las imágenes segmentadas manualmente.

5.2. Experimentos de Reconocimiento de Patrones

Después de obtener las imágenes del ROI, se realiza un proceso de reconocimiento de patrones con el fin de poder clasificar las imágenes correctamente. Las imágenes que participan en este proceso son las 175 imágenes que se procesaron correctamente con el

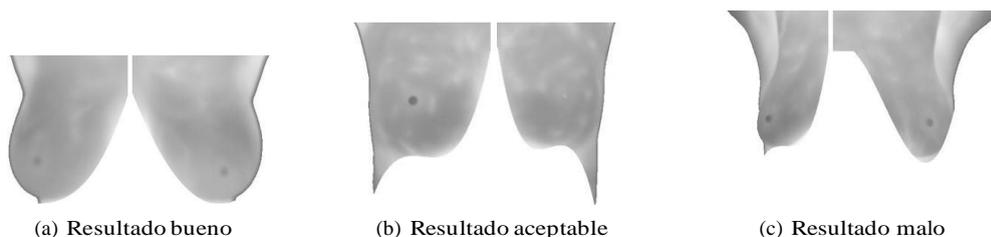


Figura 5.2 – Categorías de Resultados de ROI

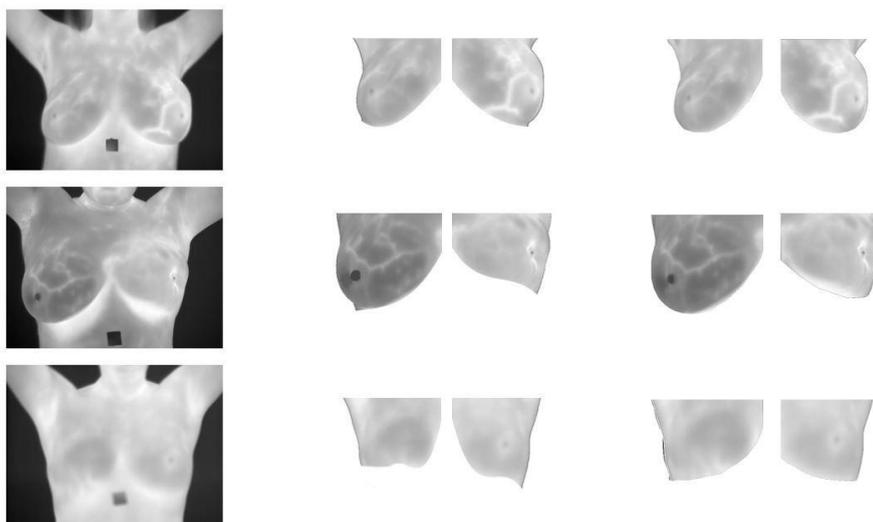


Figura 5.3 – Resultados de segmentación automática y segmentación manual. En la columna del centro, los resultados de la segmentación automática, en la última columna resultados de la segmentación manual

| Clase | Total | Porcentaje |
|---------|-------|------------|
| Sano | 142 | 81.14 % |
| Enfermo | 33 | 18.86 % |
| Total | 175 | 100 % |

Cuadro 5.3 – Resumen de instancias a ocupar en experimentos

método de segmentación. Como se mencionó en el capítulo de la metodología se ocupa una Red Neuronal Artificial de retropropagación y una función de activación sigmoïdal. Pero antes de realizar los experimentos hay que definir la arquitectura de la red y los valores de los hiperparámetros. Para los hiperparámetros se realizan experimentos particulares que se describen posteriormente en el documento pero para la arquitectura se define que la Red Neuronal Artificial tenga solo una capa oculta, el número de neuronas en esa capa es un hiperparámetro que se ajustará en los experimentos.

5.2.1. Balanceo de base de datos

De las 175 imágenes que se consideran, el Cuadro 5.3 muestra que se tiene una base desbalanceada. Con el problema del desbalanceo y el posible problema de sobreajuste debido a la clase dominante, se realiza un balanceo manual, se define que cada experimento tendrá 60 instancias, 30 instancias de la clase Enfermo y 30 de la clase Sano. Sin embargo para considerar todos los datos en los experimentos, se realizan 10 experimentos por vector de características, siendo la selección de las 30 instancias de cada clase de forma aleatoria para

asegurar variabilidad y tener una probabilidad alta de que todos los datos sean considerados a lo largo de todos los experimentos. De tal forma que en todos los experimentos este proceso de balanceo será el primer paso a realizar con el conjunto de datos que se esté tratando.

5.2.2. Resultados sin búsqueda de mejores hipermetros

Inicialmente se realizaron experimentos con todos los Vectores de Características que se describieron en el capítulo de la Metodología, para estos experimentos iniciales se estableció un valor fijo para los hiperparámetros de la Red Neuronal Artificial que se propone deben de ajustarse para obtener el mejor resultado posible. Para la validación de todos los experimentos se hace una validación cruzada con 3 folds. El Cuadro 5.4 lista los hiperparámetros y el valor fijo que se establece. A continuación se listan los 10 experimentos descritos en la subsección de

| hiperparámetro | Valor |
|-------------------------|------------------------------|
| Tasa de aprendizaje | 0.3 |
| Momentum | 0.2 |
| Tiempo de entrenamiento | 500 epocas |
| Neuronas en capa oculta | $\frac{atributos+clases}{2}$ |

Cuadro 5.4 – Lista de hiperparámetros y sus valores fijos de Red Neuronal

balanceo de datos para cada uno de los vectores de características y las matrices de confusión de cada uno de los experimentos de cada vector.

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 58.33 % | 53.55 % | 63.33 % |
| 2 | 63.33 % | 70 % | 56.7 % |
| 3 | 88.33 % | 86.7 % | 90 % |
| 4 | 83.33 % | 80 % | 86.7 % |
| 5 | 73.33 % | 76.7 % | 70 % |
| 6 | 85 % | 86.7 % | 83.33 % |
| 7 | 81.67 % | 76.7 % | 86.7 % |
| 8 | 83.33 % | 80 % | 86.7 % |
| 9 | 86.67 % | 80 % | 93.3 % |
| 10 | 76.67 % | 70 % | 83.3 % |
| Media | 78.5 % | 79.6 % | 76.8 % |
| Desviación Estándar | 10.15 % | 11.4 % | 9.32 % |

Cuadro 5.5 – Resultados de reconocimiento de patrones con vector 1

| | | | | | | | | | | | | | | | | | | | | | | | |
|----------------|----|----|---------|----|----|----------------|----|----|---------|----|----|----------------|----|----|---------|----|----|---------|----|----|---------|----|----|
| Sano | | | Enfermo | | | Sano | | | Enfermo | | | Sano | | | Enfermo | | | | | | | | |
| Sano | 16 | 14 | Sano | 21 | 9 | Sano | 26 | 4 | Sano | 24 | 6 | Sano | 23 | 7 | Sano | 26 | 4 | Sano | 24 | 6 | Sano | 21 | 9 |
| Enfermo | 11 | 19 | Enfermo | 13 | 17 | Enfermo | 3 | 27 | Enfermo | 4 | 26 | Enfermo | 9 | 21 | Enfermo | 5 | 25 | Enfermo | 4 | 26 | Enfermo | 4 | 26 |
| experimento 1 | | | | | | experimento 2 | | | | | | experimento 3 | | | | | | | | | | | |
| Sano | | | Enfermo | | | Sano | | | Enfermo | | | Sano | | | Enfermo | | | | | | | | |
| Sano | 24 | 6 | Sano | 23 | 7 | Sano | 26 | 4 | Sano | 24 | 6 | Sano | 24 | 6 | Sano | 24 | 6 | Sano | 21 | 9 | Sano | 21 | 9 |
| Enfermo | 4 | 26 | Enfermo | 9 | 21 | Enfermo | 5 | 25 | Enfermo | 4 | 26 | Enfermo | 2 | 28 | Enfermo | 5 | 25 | Enfermo | 4 | 26 | | | |
| experimento 4 | | | | | | experimento 5 | | | | | | experimento 6 | | | | | | | | | | | |
| Sano | | | Enfermo | | | Sano | | | Enfermo | | | Sano | | | Enfermo | | | | | | | | |
| Sano | 23 | 7 | Sano | 24 | 6 | Sano | 24 | 6 | Sano | 23 | 7 | Sano | 24 | 6 | Sano | 24 | 6 | Sano | 21 | 9 | Sano | 21 | 9 |
| Enfermo | 4 | 26 | Enfermo | 4 | 26 | Enfermo | 4 | 26 | Enfermo | 4 | 26 | Enfermo | 2 | 28 | Enfermo | 4 | 26 | Enfermo | 4 | 26 | | | |
| experimento 7 | | | | | | experimento 8 | | | | | | experimento 9 | | | | | | | | | | | |
| Sano | | | Enfermo | | | Sano | | | Enfermo | | | Sano | | | Enfermo | | | | | | | | |
| Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 |
| Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 |
| experimento 10 | | | | | | experimento 10 | | | | | | experimento 10 | | | | | | | | | | | |

Figura 5.4 – Matrices obtenidas en cada experimento con vector 1

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 63.33 % | 93.3 % | 33.3 % |
| 2 | 43.33 % | 23.3 % | 63.3 % |
| 3 | 53.33 % | 40 % | 66.7 % |
| 4 | 66.67 % | 93.3 % | 40 % |
| 5 | 46.67 % | 83.3 % | 10 % |
| 6 | 65 % | 93.3 % | 36.7 % |
| 7 | 50 % | 56.7 % | 43.3 % |
| 8 | 46.67 % | 73.3 % | 20 % |
| 9 | 43.33 % | 63.3 % | 23.3 % |
| 10 | 48.33 % | 83.3 % | 13.3 % |
| Media | 52.67 % | 51.2 % | 56.5 % |
| Desviación Estándar | 9.03 % | 6.99 % | 19.8 % |

Cuadro 5.6 – Resultados de reconocimiento de patrones con vector 2

| | | | | | | | | | | | |
|----------------|----|---------|---------------|---------|----|---------------|--|---------|----|---------|--|
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 28 | 2 | | Sano | 7 | 23 | | Sano | 12 | 18 | |
| Enfermo | 20 | 10 | | Enfermo | 11 | 19 | | Enfermo | 10 | 20 | |
| experimento 1 | | | experimento 2 | | | experimento 3 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 28 | 2 | | Sano | 25 | 5 | | Sano | 28 | 2 | |
| Enfermo | 18 | 12 | | Enfermo | 27 | 3 | | Enfermo | 19 | 11 | |
| experimento 4 | | | experimento 5 | | | experimento 6 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 17 | 13 | | Sano | 22 | 8 | | Sano | 19 | 11 | |
| Enfermo | 17 | 13 | | Enfermo | 24 | 6 | | Enfermo | 23 | 7 | |
| experimento 7 | | | experimento 8 | | | experimento 9 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 25 | 5 | | Sano | 25 | 5 | | Sano | 25 | 5 | |
| Enfermo | 26 | 4 | | Enfermo | 26 | 4 | | Enfermo | 26 | 4 | |
| experimento 10 | | | | | | | | | | | |

Figura 5.5 – Matrices obtenidas en cada experimento con vector 2

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 76.67 % | 83.3 % | 70 % |
| 2 | 71.67 % | 66.7 % | 76.7 % |
| 3 | 70 % | 73.3 % | 66.7 % |
| 4 | 65 % | 66.7 % | 63.3 % |
| 5 | 86.67 % | 86.7 % | 86.7 % |
| 6 | 76.67 % | 63. % | 90 % |
| 7 | 78.33 % | 80 % | 76.7 % |
| 8 | 73.33 % | 76.7 % | 70 % |
| 9 | 88.33 % | 83.3 % | 93.3 % |
| 10 | 75 % | 70 % | 80 % |
| Media | 76.17 % | 77.4 % | 75.7 % |
| Desviación Estándar | 7.11 % | 8.8 % | 6.9 % |

Cuadro 5.7 – Resultados de reconocimiento de patrones con vector 3

| | | | | | | | | | | | |
|----------------|----|---------|---------------|------|----|---------------|----|------|---------|---------|----|
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 25 | 5 | Sano | 20 | 10 | Sano | 20 | 10 | Sano | 20 | 10 |
| Enfermo | 9 | 21 | Enfermo | 7 | 23 | Enfermo | 7 | 23 | Enfermo | 7 | 23 |
| experimento 1 | | | experimento 2 | | | experimento 3 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 20 | 10 | Sano | 26 | 4 | Sano | 19 | 11 | Sano | 19 | 11 |
| Enfermo | 11 | 19 | Enfermo | 4 | 26 | Enfermo | 3 | 27 | Enfermo | 3 | 27 |
| experimento 4 | | | experimento 5 | | | experimento 6 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 24 | 6 | Sano | 23 | 7 | Sano | 25 | 5 | Sano | 25 | 5 |
| Enfermo | 7 | 23 | Enfermo | 9 | 21 | Enfermo | 2 | 28 | Enfermo | 2 | 28 |
| experimento 7 | | | experimento 8 | | | experimento 9 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 | Sano | 21 | 9 |
| Enfermo | 6 | 24 | Enfermo | 6 | 24 | Enfermo | 6 | 24 | Enfermo | 6 | 24 |
| experimento 10 | | | | | | | | | | | |

Figura 5.6 – Matrices obtenidas en cada experimento con vector 3

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 71.67 % | 70 % | 73.3 % |
| 2 | 73.33 % | 66.7 % | 80 % |
| 3 | 50 % | 100 % | 0 % |
| 4 | 68.33 % | 73.3 % | 63.3 % |
| 5 | 43.33 % | 63.3 % | 23.3 % |
| 6 | 73.33 % | 73.3 % | 73.3 % |
| 7 | 83.33 % | 83.3 % | 83.3 % |
| 8 | 48.33 % | 50 % | 46.7 % |
| 9 | 66.67 % | 90 % | 43.3 % |
| 10 | 71.67 % | 80 % | 63.3 % |
| Media | 65 % | 75 % | 54.9 % |
| Desviación Estándar | 13.1 % | 13 % | 18 % |

Cuadro 5.8 – Resultados de reconocimiento de patrones con vector 4

| | | | | | | | | | | | |
|----------------|----|---------|---------------|------|----|---------------|----|------|---------|---------|----|
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 21 | 9 | Sano | 20 | 10 | Sano | 30 | 0 | Sano | 30 | 0 |
| Enfermo | 8 | 22 | Enfermo | 6 | 24 | Enfermo | 30 | 0 | Enfermo | 30 | 0 |
| experimento 1 | | | experimento 2 | | | experimento 3 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 22 | 8 | Sano | 19 | 11 | Sano | 22 | 8 | Sano | 22 | 8 |
| Enfermo | 11 | 19 | Enfermo | 23 | 7 | Enfermo | 8 | 22 | Enfermo | 8 | 22 |
| experimento 4 | | | experimento 5 | | | experimento 6 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 25 | 5 | Sano | 15 | 15 | Sano | 27 | 3 | Sano | 27 | 3 |
| Enfermo | 5 | 25 | Enfermo | 16 | 14 | Enfermo | 17 | 13 | Enfermo | 17 | 13 |
| experimento 7 | | | experimento 8 | | | experimento 9 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 24 | 6 | Sano | 24 | 6 | Sano | 24 | 6 | Sano | 24 | 6 |
| Enfermo | 11 | 19 | Enfermo | 11 | 19 | Enfermo | 11 | 19 | Enfermo | 11 | 19 |
| experimento 10 | | | | | | | | | | | |

Figura 5.7 – Matrices obtenidas en cada experimento con vector 4

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 90 % | 90 % | 90 % |
| 2 | 70 % | 66.7 % | 73.3 % |
| 3 | 85 % | 80 % | 90 % |
| 4 | 71.67 % | 80 % | 63.3 % |
| 5 | 78.33 % | 76.7 % | 80 % |
| 6 | 85 % | 73.3 % | 96.7 % |
| 7 | 76.67 % | 73.3 % | 80 % |
| 8 | 88.33 % | 86.7 % | 90 % |
| 9 | 76.67 % | 66.7 % | 86.7 % |
| 10 | 78.33 % | 80 % | 76.7 % |
| Media | 80 % | 82.3 % | 78.7 % |
| Desviación Estándar | 6.8 % | 8.75 % | 6.4 % |

Cuadro 5.9 – Resultados de reconocimiento de patrones con vector 5

| | | | | | | | | |
|---------------|------|---------|----------------|------|---------|---------------|------|---------|
| | Sano | Enfermo | | Sano | Enfermo | | Sano | Enfermo |
| Sano | 27 | 3 | Sano | 20 | 10 | Sano | 24 | 6 |
| Enfermo | 3 | 27 | Enfermo | 8 | 22 | Enfermo | 3 | 27 |
| experimento 1 | | | experimento 2 | | | experimento 3 | | |
| | Sano | Enfermo | | Sano | Enfermo | | Sano | Enfermo |
| Sano | 24 | 6 | Sano | 23 | 7 | Sano | 22 | 8 |
| Enfermo | 11 | 19 | Enfermo | 6 | 24 | Enfermo | 1 | 29 |
| experimento 4 | | | experimento 5 | | | experimento 6 | | |
| | Sano | Enfermo | | Sano | Enfermo | | Sano | Enfermo |
| Sano | 22 | 8 | Sano | 26 | 4 | Sano | 20 | 10 |
| Enfermo | 6 | 24 | Enfermo | 3 | 27 | Enfermo | 4 | 26 |
| experimento 7 | | | experimento 8 | | | experimento 9 | | |
| | | | | Sano | Enfermo | | | |
| | | | Sano | 24 | 6 | | | |
| | | | Enfermo | 7 | 23 | | | |
| | | | experimento 10 | | | | | |

Figura 5.8 – Matrices obtenidas en cada experimento con vector 5

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 71.67 % | 73.3 % | 70 % |
| 2 | 71.67 % | 70 % | 73.3 % |
| 3 | 63.33 % | 73.3 % | 53.3 % |
| 4 | 86.67 % | 86.7 % | 86.7 % |
| 5 | 81.67 % | 83.3 % | 80 % |
| 6 | 78.33 % | 73.3 % | 83.3 % |
| 7 | 76.67 % | 66.7 % | 86.7 % |
| 8 | 71.67 % | 70 % | 73.3 % |
| 9 | 83.33 % | 73.3 % | 93.3 % |
| 10 | 88.33 % | 86.7 % | 90 % |
| Media | 77.33 % | 79 % | 76.33 % |
| Desviación Estándar | 7.8 % | 9.6 % | 7 % |

Cuadro 5.10 – Resultados de reconocimiento de patrones con vector 6

| | | | | | | | | |
|---------------|------|---------|----------------|------|---------|---------------|------|---------|
| | Sano | Enfermo | | Sano | Enfermo | | Sano | Enfermo |
| Sano | 22 | 8 | Sano | 21 | 9 | Sano | 22 | 8 |
| Enfermo | 9 | 21 | Enfermo | 8 | 22 | Enfermo | 14 | 16 |
| experimento 1 | | | experimento 2 | | | experimento 3 | | |
| | Sano | Enfermo | | Sano | Enfermo | | Sano | Enfermo |
| Sano | 26 | 4 | Sano | 25 | 5 | Sano | 22 | 8 |
| Enfermo | 4 | 26 | Enfermo | 6 | 24 | Enfermo | 5 | 25 |
| experimento 4 | | | experimento 5 | | | experimento 6 | | |
| | Sano | Enfermo | | Sano | Enfermo | | Sano | Enfermo |
| Sano | 20 | 10 | Sano | 21 | 9 | Sano | 22 | 8 |
| Enfermo | 4 | 26 | Enfermo | 8 | 22 | Enfermo | 2 | 28 |
| experimento 7 | | | experimento 8 | | | experimento 9 | | |
| | | | | Sano | Enfermo | | | |
| | | | Sano | 26 | 4 | | | |
| | | | Enfermo | 3 | 27 | | | |
| | | | experimento 10 | | | | | |

Figura 5.9 – Matrices obtenidas en cada experimento con vector 6

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 68.33 % | 76.7 % | 60 % |
| 2 | 66.67 % | 83.3 % | 50 % |
| 3 | 41.67 % | 63.3 % | 20 % |
| 4 | 53.33 % | 53.3 % | 53.3 % |
| 5 | 38.33 % | 36.7 % | 40 % |
| 6 | 75 % | 76.7 % | 73.3 % |
| 7 | 46.67 % | 86.7 % | 6.7 % |
| 8 | 73.33 % | 63.3 % | 83.3 % |
| 9 | 71.67 % | 80 % | 63.3 % |
| 10 | 56.67 % | 60 % | 53.3 % |
| Media | 59.16 % | 59 % | 59 % |
| Desviación Estándar | 13.6 % | 13.3 % | 17.5 % |

Cuadro 5.11 – Resultados de reconocimiento de patrones con vector 7

| | | | | | | | | | | | |
|---------------|----|------|----------------|----|----|---------------|---------|----|---------|------|---------|
| | | Sano | Enfermo | | | Sano | Enfermo | | | Sano | Enfermo |
| Sano | 23 | 7 | Sano | 25 | 5 | Sano | 19 | 11 | Sano | 23 | 7 |
| Enfermo | 12 | 18 | Enfermo | 15 | 15 | Enfermo | 24 | 6 | Enfermo | 8 | 22 |
| experimento 1 | | | experimento 2 | | | experimento 3 | | | | | |
| | | Sano | Enfermo | | | Sano | Enfermo | | | Sano | Enfermo |
| Sano | 16 | 14 | Sano | 11 | 19 | Sano | 23 | 7 | Sano | 24 | 6 |
| Enfermo | 14 | 16 | Enfermo | 18 | 12 | Enfermo | 8 | 22 | Enfermo | 11 | 19 |
| experimento 4 | | | experimento 5 | | | experimento 6 | | | | | |
| | | Sano | Enfermo | | | Sano | Enfermo | | | Sano | Enfermo |
| Sano | 26 | 4 | Sano | 19 | 11 | Sano | 24 | 6 | Sano | 24 | 6 |
| Enfermo | 28 | 2 | Enfermo | 5 | 25 | Enfermo | 11 | 19 | Enfermo | 11 | 19 |
| experimento 7 | | | experimento 8 | | | experimento 9 | | | | | |
| | | Sano | Enfermo | | | Sano | Enfermo | | | Sano | Enfermo |
| Sano | 18 | 12 | Sano | 18 | 12 | Sano | 18 | 12 | Sano | 18 | 12 |
| Enfermo | 14 | 16 | Enfermo | 14 | 16 | Enfermo | 14 | 16 | Enfermo | 14 | 16 |
| | | | experimento 10 | | | | | | | | |

Figura 5.10 – Matrices obtenidas en cada experimento con vector 7

5.2.3. Búsqueda de hiperparámetros

Los resultados muestran detalles interesantes, sin embargo no son buenos, por lo que se realiza una búsqueda de los mejores hiperparámetros para subir la precisión global obtenida previamente. De los resultados previos se observa que los vectores 1 y 5 son los más robustos, es decir, fueron de los que obtuvieron mejores resultados en cuanto a precisión global pero también en cuanto a las métricas de sensibilidad y especificidad, lo que indica que son los vectores donde se tienen las características más relevantes entre las clases. Es por ello que en esta sección y la siguiente solo se consideran esos vectores para los experimentos que se realizarán.

Los experimentos realizados en esta sección se realizaron de la siguiente forma, se definió una lista de posibles valores para cada uno de los hiperparámetros, estos valores se listan en el Cuadro 5.12. Para los dos vectores en cuestión se realizan los mismos diez experimentos, en cada experimento se evalúa primero todos los valores del momentum, una vez que se identifica el mejor. Después se establece el mejor valor encontrado del momentum y ahora se busca el mejor valor de los posibles de tasa de aprendizaje a lo largo de los diez experimentos. Después se busca el número de neuronas de capa oculta y finalmente el valor de tiempo de

entrenamiento. A continuación se presentan las gráficas de uno de los experimentos en el

| hiperparámetro | Valores |
|-------------------------|--|
| Momentum | 0.01, 0.05, 0.1, 0.15, 0.20, 0.25, 0.3, 0.35, 0.4, 0.45, 0.5, 0.55, 0.6 |
| Tasa de Aprendizaje | 0.05, 0.1, 0.15, 0.2, 0.25, 0.3, 0.35, 0.4, 0.45, 0.5 |
| Neuronas en Capa Oculta | 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 |
| Tiempo de Aprendizaje | 200, 300, 400, 500, 600, 700, 800, 900, 1000, 1100, 1200, 1300, 1400, 1500, 1600 |

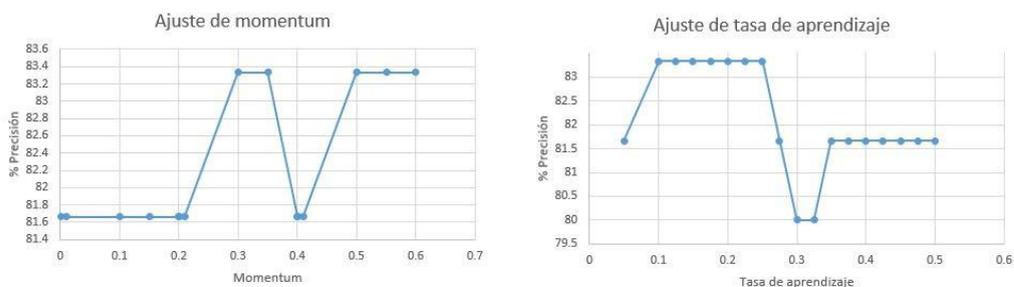
Cuadro 5.12 – Rango de valores para hiperparámetros

orden descrito, primero para momentum, después tasa de aprendizaje, número de neuronas ocupadas y finalmente tiempo de entrenamiento en la Figura 5.11 y la Figura 5.12.

Finalmente se observa el rango de los valores donde se estabilizó el comportamiento de cada hiperparámetro para cada uno de los experimentos y con los dos vectores, estos valores se van a considerar como un rango reducido del inicial que se muestran en el Cuadro 5.13, los cuales serán ocupados en la siguiente sección.

| hiperparámetro | Valores |
|-------------------------|---------------------------------|
| Momentum | 0.15, 0.2, 0.25, 0.3, 0.35, 0.4 |
| Tasa de Aprendizaje | 0.15, 0.2, 0.25, 0.3, 0.35 |
| Neuronas en Capa Oculta | 6, 7, 8, 9 |
| Tiempo de Aprendizaje | 700, 800, 900, 1000, 1100, 1200 |

Cuadro 5.13 – Hiperparámetros a ocupar



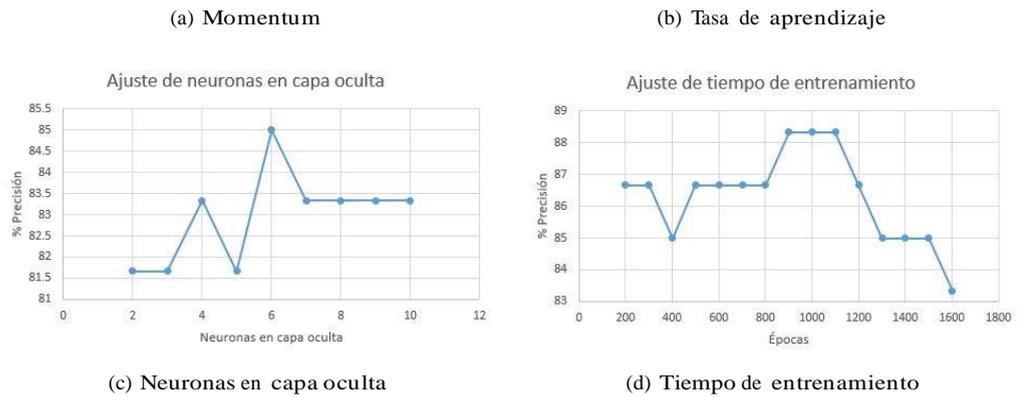


Figura 5.11 – Evaluación de distintos valores para todos los parámetros con el vector 1

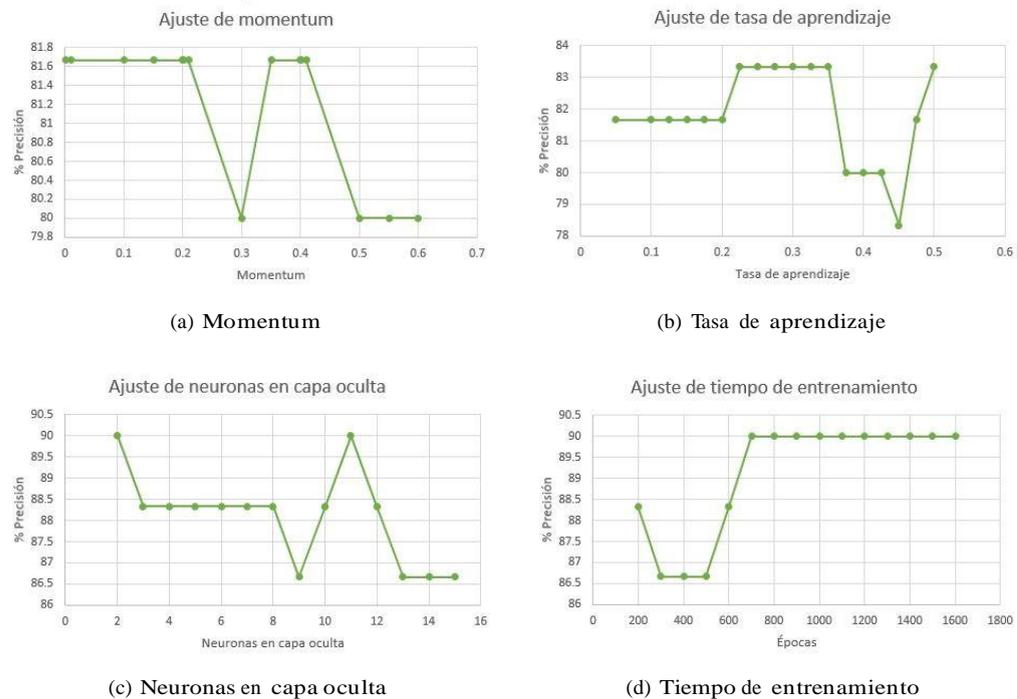


Figura 5.12 – Evaluación de distintos valores para todos los parámetros con el vector 5

5.2.4. Resultados con uso de hiperparámetros encontrados

Con el rango de hiperparámetros para el ajuste correcto a la Red Neuronal, se realiza otra vez el proceso de entrenamiento y pruebas con los vectores 1 y 5. Se realiza una vez más una validación cruzada con un valor de 3 *fold*s, con el fin de ajustar bien los datos a todos los datos, en cada *fold* se realiza un ajuste de parametros con una búsqueda del mejor valor para cada hiperparámetro con los valores que componen los conjuntos de rangos para cada hiperparámetro, es decir se propone una técnica dinámica de ajuste de hiperparámetros para cada *fold* en cada experimento. A continuación se listan los resultados.

5.2.5. Vector-1

En el Cuadro 5.14 se muestran los experimentos y sus resultados a través de la métricas de precisión global, sensibilidad y especificidad.

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 90 % | 86.67 % | 93.33 % |
| 2 | 86.66 % | 80 % | 93.33 % |
| 3 | 86.67 % | 86.67 % | 86.67 % |
| 4 | 86.66 % | 90 % | 83.33 % |
| 5 | 88.33 % | 90 % | 86.67 % |
| 6 | 85 % | 76.67 % | 93.33 % |
| 7 | 85 % | 73.33 % | 96.67 % |
| 8 | 91.67 % | 86.67 % | 96.67 % |
| 9 | 91.66 % | 90 % | 93.33 % |
| 10 | 83.33 % | 86.67 % | 80 % |
| Media | 87.5 % | 84.67 % | 90.33 % |
| Desviación Estándar | 2.71 % | 5.62 % | 5.47 % |

Cuadro 5.14 – Resultados de reconocimiento de patrones con vector 1

A continuación se muestran en la Figura 5.13 las gráficas del comportamiento de la precisión, la sensibilidad y la especificidad; en cada caso se muestra la media y el rango de la desviación estándar, esto con el propósito de identificar la uniformidad de los experimentos y la identificación de algún resultado aislado. Finalmente se listan las matrices de confusión de cada experimento en la Figura 5.14.

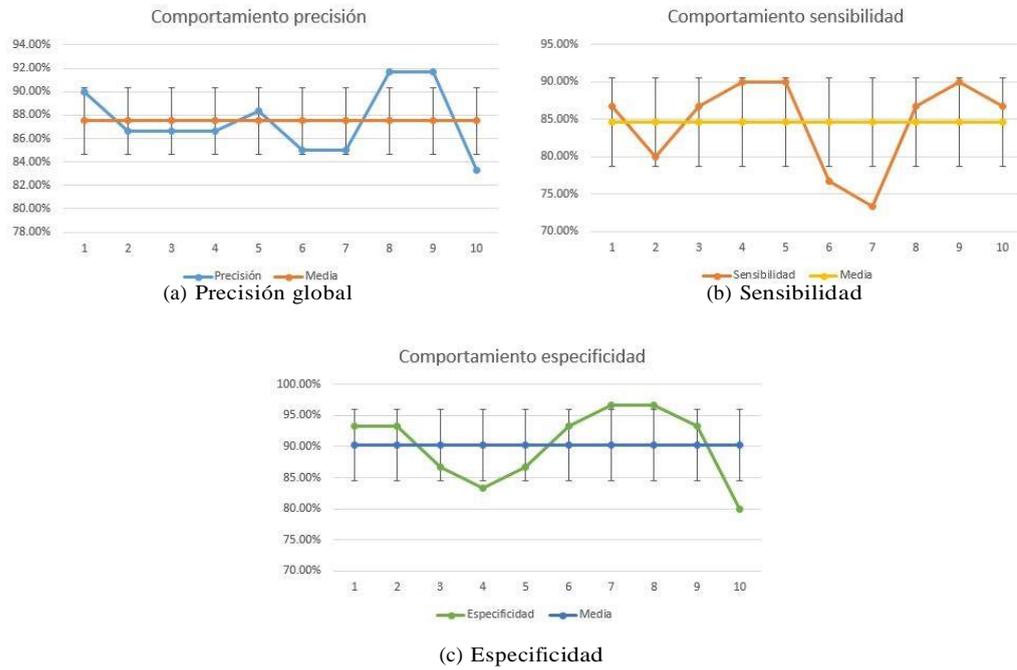


Figura 5.13 – Comportamiento de las métricas de evaluación a lo largo de los experimentos para vector 1 y ajuste de hiperparámetros

| | | | | | | |
|---------------|---------|----------------|---------|---------------|---------|--|
| Sano | Enfermo | Sano | Enfermo | Sano | Enfermo | |
| Sano | 26 | 4 | Sano | 24 | 6 | |
| Enfermo | 2 | 28 | Enfermo | 2 | 28 | |
| experimento 1 | | experimento 2 | | experimento 3 | | |
| Sano | Enfermo | Sano | Enfermo | Sano | Enfermo | |
| Sano | 27 | 3 | Sano | 27 | 3 | |
| Enfermo | 5 | 25 | Enfermo | 4 | 26 | |
| experimento 4 | | experimento 5 | | experimento 6 | | |
| Sano | Enfermo | Sano | Enfermo | Sano | Enfermo | |
| Sano | 22 | 8 | Sano | 26 | 4 | |
| Enfermo | 1 | 29 | Enfermo | 1 | 29 | |
| experimento 7 | | experimento 8 | | experimento 9 | | |
| | | Sano | Enfermo | | | |
| | | Sano | 26 | 4 | | |
| | | Enfermo | 6 | 24 | | |
| | | experimento 10 | | | | |

Figura 5.14 – Matrices obtenidas en cada experimento con vector 1 y ajuste de hiperparámetros

5.2.6. Vector-5

En el Cuadro 5.15 se muestran los experimentos y sus resultados a través de la métricas de precisión global, sensibilidad y especificidad.

| Experimento | Precisión global | Sensibilidad | Especificidad |
|---------------------|------------------|--------------|---------------|
| 1 | 86.67 % | 76.67 % | 96.67 % |
| 2 | 91.66 % | 83.33 % | 100 % |
| 3 | 83.33 % | 86.67 % | 80 % |
| 4 | 75 % | 66.67 % | 83.33 % |
| 5 | 85 % | 80 % | 90 % |
| 6 | 93.33 % | 90 % | 96.67 % |
| 7 | 88.33 % | 83.33 % | 93.33 % |
| 8 | 81.67 % | 86.67 % | 76.67 % |
| 9 | 85 % | 83.33 % | 86.67 % |
| 10 | 85 % | 86.67 % | 83.33 % |
| Media | 85.5 % | 82.33 % | 88.67 % |
| Desviación Estándar | 4.89 % | 6.33 % | 7.48 % |

Cuadro 5.15 – Resultados de reconocimiento de patrones con vector 5 con ajuste de hiperparámetros

A continuación se muestran en la Figura 5.15 las gráficas del comportamiento de la precisión, la sensibilidad y la especificidad; en cada caso se muestra la media y el rango de la desviación estándar, esto con el propósito de identificar la uniformidad de los experimentos y la identificación de algún resultado aislado.

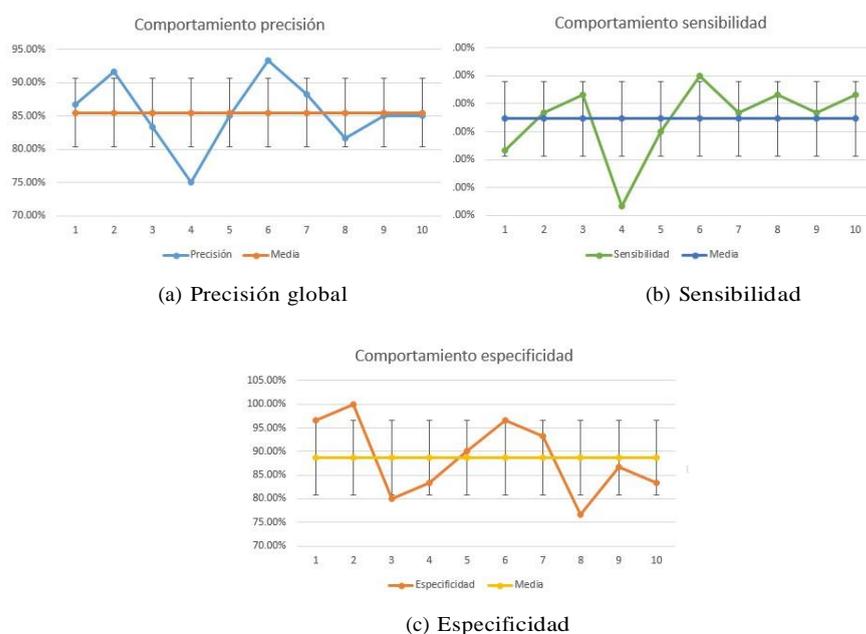


Figura 5.15 – Comportamiento de las métricas de evaluación a lo largo de los experimentos para vector 5 y ajuste de hiperparámetros

Y a continuación se listan en la Figura 5.16 las matrices de confusión de cada experimento.

| | | | | | | | | | | | |
|----------------|----|---------|---------------|------|----|---------------|----|------|---------|---------|----|
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 23 | 7 | Sano | 25 | 5 | Sano | 26 | 4 | Sano | 27 | 3 |
| Enfermo | 1 | 29 | Enfermo | 0 | 30 | Enfermo | 6 | 24 | Enfermo | 1 | 29 |
| experimento 1 | | | experimento 2 | | | experimento 3 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 20 | 10 | Sano | 24 | 6 | Sano | 27 | 3 | Sano | 25 | 5 |
| Enfermo | 5 | 25 | Enfermo | 3 | 27 | Enfermo | 1 | 29 | Enfermo | 4 | 26 |
| experimento 4 | | | experimento 5 | | | experimento 6 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 25 | 5 | Sano | 26 | 4 | Sano | 25 | 5 | Sano | 26 | 4 |
| Enfermo | 2 | 28 | Enfermo | 7 | 23 | Enfermo | 4 | 26 | Enfermo | 5 | 25 |
| experimento 7 | | | experimento 8 | | | experimento 9 | | | | | |
| Sano | | Enfermo | | Sano | | Enfermo | | Sano | | Enfermo | |
| Sano | 26 | 4 | Sano | 26 | 4 | Sano | 26 | 4 | Sano | 26 | 4 |
| Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 | Enfermo | 5 | 25 |
| experimento 10 | | | | | | | | | | | |

Figura 5.16 – Matrices obtenidas en cada experimento con vector 5 y ajuste de hiperparámetros

5.3. Discusión

En el tema del método de segmentación automática se detectó que no se pudo ejecutar la técnica en algunas imágenes debido a que estas presentaban regiones a lo largo del cuerpo con intensidades elevadas de color, probablemente síntoma de algún otro padecimiento que se manifestaba en otras regiones del cuerpo a través de la temperatura, pues existían colores claros en regiones distintas a las que se planteó (debajo de los senos, axilas y en el cuello), situación que hizo que el algoritmo funcione de forma errática, incompleta o trunca.

Dejando de lado las instancias que no se pudieron procesar, en las que sí se pudo, se tuvo un porcentaje alto de imágenes buenas o aceptables, indicativo de que la técnica es competitiva, resalta el hecho de lograr estos resultados con sólo el uso de técnicas básicas de procesamiento de imágenes digitales como mejora de contraste, umbralización por Otsu y operaciones estadísticas. Las instancias que presentaron malos resultados fueron influenciadas en algunos casos por la irregularidad de los pechos de algunos pacientes, procedimientos previos realizados o algunos pechos pequeños resultaron ser también difíciles de procesar.

Ya con la ROI extraída de la mayoría de las imágenes y su debida extracción de las características propuestas, la forma de evaluar que tan significativas eran estas últimas fue a través de un proceso de reconocimiento de patrones. De igual forma este proceso determinaría qué tan buena había sido la región de interés segmentada, pues si se tiene una segmentación con pérdida de información esto iba a afectar el proceso de clasificación.

Los resultados de la primera fase de experimentos con hiperparámetros fijos indican que los vectores 2, 4 y 7 son los que menos aportaron información útil para poder clasificar correctamente los datos, es claro que estos vectores son descartados por la misma razón. En el caso de los vectores restantes, si bien sus resultados son relativamente similares entre

ellos, se optó solo trabajar con el vector 1 y 5 pues fueron los de precisión mayor, además que mostraron comportamientos uniformes a lo largo de todos los experimentos. Teniendo solo esos dos vectores, sus resultados son aceptables pero se tenía la hipótesis de que haciendo un mejor ajuste de los hiperparámetros del clasificador se podía obtener una mayor precisión.

En la búsqueda de hiperparámetros se demuestra con las gráficas como dentro de la gama de valores que se prueban para cada hiperparámetro, su comportamiento mostró tener diferentes comportamientos; ya sea un comportamiento estabilizado en su precisión en todas las pruebas, o en tener un pico de precisión, descender, estabilizarse y después mantenerse o descender. Estos resultados demuestran como el clasificador es muy sensible a pequeñas variaciones en sus hiperparámetros, con lo cual se concluye que es vital el correcto ajuste de estos valores para cada experimento.

En la última fase de experimentos ya con el ajuste de hiperparámetros, los resultados muestran una considerable mejoría en general en todos los experimentos. El vector 1 queda como el mejor dado que tuvo una media más alta en comparación del vector 5, pero además en todos sus experimentos se tuvo un mejor resultado, alcanzando inclusive precisiones de 90% o más, la desviación estándar promedio de todos los experimentos confirma esta aseveración al tener una variabilidad entre ellos pequeña. Por otro lado el vector 5 si bien la precisión global de todos los experimentos no está tan alejada de la que se obtuvo con el vector 1, tuvo resultados más irregulares a lo largo de todos sus experimentos, situación que se comprueba con una desviación estándar mayor. Esto queda de manifiesto en el experimento 4 donde inclusive se tuvo una precisión global de 75 %, bastante baja a comparación de los demás resultados, a pesar de ello fue interesante observar que con este vector se tuvo la precisión global más alta para un experimento particular que fue la de 93.33 %, en dicho experimento solo se clasificaron mal cuatro instancias de las 60 del experimento, un resultado remarcable.

Finalmente al hacer la comparación de los resultados con otras metodologías se puede apreciar que el propuesto es competitivo, en el Cuadro 5.16 se muestran trabajos relacionados, el número de instancias que consideran, así como sus resultados en precisión, sensibilidad y especificidad. Es claro que nuestros experimentos son más robustos como se mencionó, es la única metodología que considera más de 150 instancias. Otro hecho que cabe resaltar y que se aprecia en el cuadro es el método de segmentación de la región de interés, como se mencionó no es una tarea trivial y muchos optan por hacer una segmentación manual o semi-automática, la metodología propuesta realiza una segmentación automática y los resultados obtenidos son comparables con los de investigaciones recientes, Lessa et al. [37] hace uso igual de una RNA y obtiene una precisión menor a la del método propuesto y en las demás propuestas salvo en la de Sayed et al. [57] se tiene una precisión solo un poco mayor a la obtenida, sin embargo varios de estos métodos no hacen uso de la mayoría de las imágenes presentes en la base de datos y como se demostró en los resultados de los experimentos individuales con cada vector de características, hay imágenes que son más separables que otras. Si sólo se tomaran de forma

individual los resultados de cada experimento y no el promedio, nuestra metodología obtuvo en un experimento un 93.3 % de precisión, colocando el método solo por debajo del de Sayed et al. [57]. Por todas estas razones se puede considerar la metodología propuesta como una de las más completas y que sin duda puede mejorarse.

| Autores | Instancias | Método de segmentación | Precisión | Sensibilidad | Especificidad |
|----------------------|------------------------------|------------------------|-----------|--------------|---------------|
| Sayed et al. [57] | 63 (29 normal, 34 anormal) | Automático | 96.83 % | 94.87 % | 100 % |
| Krawczyk et al. [34] | 146 (117 normal, 29 anormal) | Manual | 88 % | | |
| Lessa et al. [37] | 94 (48 normal, 46 anormal) | Semi-automático | 85 % | 87 % | 83 % |
| Madhavi et al. [39] | 67 (43 normal, 24 anormal) | Semi-automático | 89 % | 86 % | 100 % |
| Sathish et al. [56] | 100 (53 normal, 47 anormal) | Automático | 91 % | 87.2 % | 94.3 % |
| Gogoi et al. [24] | 80 (45 normal, 35 anormal) | Semi-automático | 87.5 % | 95 % | 80 % |
| Método propuesto | 175 (142 normal, 33 anormal) | Automático | 87.5 % | 86.7 % | 90 % |

Cuadro 5.16 – Estudios similares en la detección de anomalías en imágenes termográficas de pechos

Conclusiones y Trabajo Futuro

En la investigación se concluyó la elaboración de un método de segmentación de la región de interés de forma automática, los resultados fueron buenos con perspectivas de mejora con más trabajo en la técnica. Una vez con las ROI se propusieron características a extraer, tanto de primer orden como de segundo orden (Textura), características que se demuestra en el trabajo relacionado que han brindado los mejores resultados, sin embargo una diferencia con el resto de la literatura es que las características de primer orden no fueron extraídas únicamente del histograma de la imagen, también se hizo una extracción con base a las matrices de temperatura asociadas a cada imagen. Esta fuente de información que no había sido tan ocupada demostró ser bastante útil pues los patrones presentes ayudaron a realizar una clasificación adecuada, y es que en la investigación los vectores de características que dieron los mejores resultados resultaron tener como una de las fuentes de información las matrices de temperatura, esto demuestra que este conjunto de datos es relevante y debe ser considerado en experimentos de este tipo.

Por otro lado, en la literatura hay un sesgo en varios de los experimentos seleccionados, muchos autores no muestran la forma de selección de las imágenes con las que hacen pruebas, no hay metodologías que expliquen este procedimiento y en muchos de los casos, los autores hacen una selección de un conjunto de imágenes y no prueban con la totalidad o mayoría de las imágenes que componen a la base de datos. En este proyecto se hicieron experimentos más robustos, considerando la mayoría de las imágenes de forma aleatoria en la sección de cada imagen y a la vez de forma controlada al determinar el número de experimentos así como el número de instancias totales y por clase presentes en cada experimento, con ello se introdujo una variabilidad alta, donde quedó demostrado que en la mayoría de los experimentos hubo resultados muy buenos pero que también hubo algunos donde se presentaron resultados pobres, esto demuestra que hay imágenes donde se marcan más las diferencias en la información de sus patrones y que a pesar de ello, la metodología propuesta dio un resultado promedio bastante bueno al final.

Finalmente otro detalle relevante en la consecución de los resultados obtenidos fue el proceso de la búsqueda de mejores hiperparámetros para la Red Neuronal Artificial con el conjunto de datos que se estuviera procesando en un determinado momento. Los resultados

mostraron una mejoría significativa con la realización de esta búsqueda así como el hecho de que las Redes Neuronales Artificiales son muy sensibles a pequeñas variaciones en estos hiperparámetros.

6.1. Trabajo Futuro

Como trabajo futuro se consideran varias situaciones que podrían explorarse más a fondo. Uno de ellos es considerar todas las direcciones en las cuales se pueden extraer las características basadas en la matriz de co-ocurrencia de niveles de grises, en esta investigación se exploró sólo en la dirección horizontal. Recordando que las características de este tipo describen la textura en una imagen y dado que las anomalías que puedan conllevar a un cáncer de mama suelen ser amorfas, sería interesante considerar las texturas y características que se puedan detectar analizando otras direcciones.

Por otro lado esta investigación sólo considero como método de clasificación a la Red Neuronal Artificial, sin embargo existen diversos métodos que podrían proporcionar resultados similares o tal vez mejores dadas las características que se consideran, es por ello que en un trabajo futuro hay que realizar más experimentos con distintos métodos de clasificación como las máquinas de vectores de soporte (SVM), árboles de decisión, k vecinos más cercanos, bosques aleatorios entre otros.

Finalmente un enfoque que sería interesante abordar y que está teniendo un auge grande es el del aprendizaje profundo. En este caso lo que se podría investigar más a fondo sería hacer uso de una red neuronal convolucional (CNN) como extractor de características, dado que este tipo de redes se pueden diseñar para extraer características desde lo más general hasta lo más específico así que sin duda podrían proveer nuevos patrones, con estas características posteriormente se podría ocupar la misma RNA propuesta en la investigación y comparar los resultados.

A Publicaciones

A raíz de la siguiente investigación se han derivado los siguientes artículos:

- Sánchez-Ruiz D., Olmos-Pineda, I., & Olvera-López, J. A. *Automatic Segmentation in Breast Thermographic Images Based on Local Pattern Variations*. 10th Mexican Conference on Pattern Recognition Cholula, Pue., Mexico, 2018. (Reconocimiento a mejor trabajo en la sesión de posters)
- Sánchez-Ruiz D., Olmos-Pineda, I., & Olvera-López, J. A. *Automatic ROI Segmentation and Classification on Breast Thermogram Images*. 6th International Symposium on Language & Knowledge Engineering, Puebla, Pue., Mexico, 2018. **En revisión**

Bibliografía

- [1] About feature scaling and normalization. http://sebastianraschka.com/Articles/2014_about_feature_scaling.html#about-min-max-scaling. Accessed: 2018-05-28.
- [2] Asimetría y curtosis. <http://www.universoformulas.com/estadistica/descriptiva/asimetria-curtosis/>. Accessed: 2018-05-27.
- [3] Flir sc620, flir sc640 flir sc660 specifications. <http://www.flir.com.hk/corporate/display/?id=41965>. Accessed: 2018-05-26.
- [4] How does an ir camera work. <http://www.flir.com.hk/corporate/display/?id=41523>. Accessed: 2018-05-26.
- [5] Staring focal plane arrays (fpas). <http://www.flir.com.hk/corporate/display/?id=51939>. Accessed: 2018-05-26.
- [6] What is infrared? <http://www.flir.com.hk/corporate/display/?id=41536>. Accessed: 2018-05-26.
- [7] M. Abdel-Nasser, A. Saleh, A. Moreno, and D. Puig. Automatic nipple detection in breast thermograms. *Expert Systems with Applications*, 64:365–374, 2016.
- [8] H. Alexander Mostovoy and B. DHMS. Clinical applications of medical thermography. 2009.
- [9] M. A. Ali, G. I. Sayed, T. Gaber, A. E. Hassanien, V. Snasel, and L. F. Silva. Detection of breast abnormalities of thermograms based on a new segmentation method. In *Computer Science and Information Systems (FedCSIS), 2015 Federated Conference on*, pages 255–261. IEEE, 2015.
- [10] E. Alpaydin. *Machine learning: the new AI*. MIT Press, 2016.
- [11] T. B. Borchardt, A. Conci, R. C. Lima, R. Resmini, and A. Sanchez. Breast thermography from an image processing viewpoint: A survey. *Signal Processing*, 93(10):2785–2803, 2013.
- [12] W. Burger and M. J. Burge. *Principles of digital image processing: core algorithms*. Springer

Bibliografía

Science & Business Media, 2009.

- [13] W. Burger and M. J. Burge. *Principles of digital image processing: fundamental techniques*. Springer Science & Business Media, 2010.
- [14] W. Burger and M. J. Burge. *Principles of Digital Image Processing: Advanced Methods*. Springer Science & Business Media, 2013.
- [15] J. D. Calderón-Contreras, M. I. Chacón-Murguía, A. J. Villalobos-Montiel, and L. Ortega-Máynez. A fuzzy computer aided diagnosis system using breast thermography. In *Biomedical Imaging (ISBI), 2015 IEEE 12th International Symposium on*, pages 105–108. IEEE, 2015.
- [16] A. Conci, S. S. Galvão, G. O. Sequeiros, D. C. Saade, and T. MacHenry. A new measure for comparing biomedical regions of interest in segmentation of digital images. *Discrete Applied Mathematics*, 197:103–113, 2015.
- [17] N. R. Council et al. *Mammography and beyond: developing technologies for the early detection of breast cancer*. National Academies Press, 2001.
- [18] K. Doi. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. *Computerized medical imaging and graphics*, 31(4-5):198–211, 2007.
- [19] M. Fauci, R. Breiter, W. Cabanski, W. Fick, R. Koch, J. Ziegler, and S. Gunapala. Medical infrared imaging—differentiating facts from fiction, and the impact of high precision quantum well infrared photodetector camera systems, and other factors, in its reemergence. *Infrared physics & technology*, 42(3-5):337–344, 2001.
- [20] P. Flach. *Machine learning: the art and science of algorithms that make sense of data*. Cambridge University Press, 2012.
- [21] K.-S. Fu and J. Mui. A survey on image segmentation. *Pattern recognition*, 13(1):3–16, 1981.
- [22] T. Gaber, G. Ismail, A. Anter, M. Soliman, M. Ali, N. Semary, A. E. Hassanien, and V. Snasel. Thermogram breast cancer prediction approach based on neutrosophic sets and fuzzy c-means algorithm. In *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, pages 4254–4257. IEEE, 2015.
- [23] J. Gershon-Cohen, J. Haberman-Brueschke, and E. E. Brueschke. Medical thermography: a summary of current status. *Radiologic clinics of North America*, 3(3):403, 1965.
- [24] U. R. Gogoi, M. K. Bhowmik, A. K. Ghosh, D. Bhattacharjee, and G. Majumdar. Discriminative feature selection for breast abnormality detection and accurate classification of thermograms. In *Innovations in Electronics, Signal Processing and Communication (IESC), 2017 International Conference on*, pages 39–44. IEEE, 2017.

Bibliografía

- [25] U. R. Gogoi, G. Majumdar, M. K. Bhowmik, A. K. Ghosh, and D. Bhattacharjee. Breast abnormality detection through statistical feature analysis using infrared thermograms.

- In *Advanced Computing and Communication (ISACC), 2015 International Symposium on*, pages 258–265. IEEE, 2015.
- [26] M. A. Hall. *Correlation-based Feature Subset Selection for Machine Learning*. PhD thesis, University of Waikato, Hamilton, New Zealand, 1998.
- [27] M. A. Hall. Correlation-based feature selection for machine learning. 1999.
- [28] M. Hall-Beyer. Gcm texture: a tutorial. *National Council on Geographic Information and Analysis Remote Sensing Core Curriculum*, 2000.
- [29] R. M. Haralick, K. Shanmugam, et al. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6):610–621, 1973.
- [30] R. M. Haralick and L. G. Shapiro. Image segmentation techniques. *Computer vision, graphics, and image processing*, 29(1):100–132, 1985.
- [31] R. L. Hoffman. Thermography in the detection of breast malignancy. *American Journal of Obstetrics & Gynecology*, 98(5):681–686, 1967.
- [32] H. Jeffreys and B. Jeffreys. Lagrange’s interpolation formula. *Methods of Mathematical Physics*, page 260, 1988.
- [33] J. Keyserlingk, P. Ahlgren, E. Yu, N. Belliveau, and M. Yassa. Functional infrared imaging of the breast. *IEEE Engineering in Medicine and Biology Magazine*, 19(3):30–41, 2000.
- [34] B. Krawczyk and G. Schaefer. A hybrid classifier committee for analysing asymmetry features in breast thermograms. *Applied Soft Computing*, 20:112–118, 2014.
- [35] B. Kröse, B. Krose, P. van der Smagt, and P. Smagt. An introduction to neural networks. 1993.
- [36] W. H. Land Jr and E. A. Verheggen. Multiclass primal support vector machines for breast density classification. *International journal of computational biology and drug design*, 2(1):21–57, 2009.
- [37] V. Lessa and M. Marengoni. Applying artificial neural network for the classification of breast cancer using infrared thermographic images. In *International Conference on Computer Vision and Graphics*, pages 429–438. Springer, 2016.
- [38] A. Levy, A. Dayan, M. Ben-David, and I. Gannot. A new thermography-based approach to early detection of cancer utilizing magnetic nanoparticles theory simulation and in vitro validation. *Nanomedicine: Nanotechnology, Biology and Medicine*, 6(6):786–796, 2010.

-
- [39] V. Madhavi and T. C. Bobby. Thermal imaging based breast cancer analysis using bemd and uniform rlbp. In *Biosignals, Images and Instrumentation (ICBSII), 2017 Third International Conference on*, pages 1–6. IEEE, 2017.

- [40] T. M. Mejía, M. G. Pérez, V. H. Andaluz, and A. Conci. Automatic segmentation and analysis of thermograms using texture descriptors for breast cancer detection. In *Computer Aided System Engineering (APCASE), 2015 Asia-Pacific Conference on*, pages 24–29. IEEE, 2015.
- [41] C. Meola. *Infrared thermography recent advances and future trends*. Bentham Science Publishers, 2012.
- [42] T. M. Mitchell et al. *Machine learning*. WCB. McGraw-Hill Boston, MA:, 1997.
- [43] M. Moghbel and S. Mashohor. A review of computer assisted detection/diagnosis cad in breast thermography for breast cancer detection. *Artificial Intelligence Review*, 39(4):305–313, 2013.
- [44] N. A. E.-R. Mohamed. Breast cancer risk detection using digital infrared thermal images. 2015.
- [45] M. R. K. Mookiah, U. R. Acharya, and E. Ng. Data mining technique for breast cancer detection in thermograms using hybrid feature extraction strategy. *Quantitative InfraRed Thermography Journal*, 9(2):151–165, 2012.
- [46] A. Mostovoy. Breast thermography and clinical applications. 2008.
- [47] A. C. Müller and S. Guido. *Introduction to machine learning with Python: a guide for data scientists*. "O'Reilly Media, Inc.", 2016.
- [48] J. Nahar, T. Imam, K. S. Tickle, A. S. Ali, and Y.-P. P. Chen. Computational intelligence for microarray data and biomedical image analysis for the early diagnosis of breast cancer. *Expert Systems with Applications*, 39(16):12371–12377, 2012.
- [49] N. Otsu. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1):62–66, 1979.
- [50] S. Pramanik, D. Bhattacharjee, and M. Nasipuri. Texture analysis of breast thermogram for differentiation of malignant and benign breast. In *Advances in Computing, Communications and Informatics (ICACCI), 2016 International Conference on*, pages 8–14. IEEE, 2016.
- [51] S. Pramanik, M. K. Bhowmik, D. Bhattacharjee, and M. Nasipuri. Hybrid intelligent techniques for segmentation of breast thermograms. In *Hybrid Soft Computing for Image Segmentation*, pages 255–289. Springer, 2016.
- [52] U. Raghavendra, U. Rajendra Acharya, E. Ng, J.-H. Tan, and A. Gudigar. An integrated index for breast cancer identification using histogram of oriented gradient and kernel lo-

quality preserving projection features extracted from thermograms. *Quantitative InfraRed Thermography Journal*, 13(2):195–209, 2016.

- [53] R. Resmini, A. Conci, L. F. da Silva, G. O. Sequeiros, F. Araújo, C. de Araújo, A. dos Santos Araújo, R. Rodríguez-Ramos, and F. Lebon. Application of infrared images to diagnosis and modeling of breast. In *Application of Infrared to Biomedical Sciences*, pages 159–173. Springer, 2017.
- [54] F. Rosenblatt. Principles of neurodynamics. 1962.
- [55] A. V. Sabadías. *Estadística descriptiva e inferencial*, volume 8. Univ de Castilla La Mancha, 1995.
- [56] D. Sathish, S. Kamath, K. Prasad, R. Kadavigere, and R. J. Martis. Asymmetry analysis of breast thermograms using automated segmentation and texture features. *Signal, Image and Video Processing*, 11(4):745–752, 2017.
- [57] G. I. Sayed, M. Soliman, and A. E. Hassanien. Bio-inspired swarm techniques for thermogram breast cancer detection. In *Medical Imaging in Clinical Applications*, pages 487–506. Springer, 2016.
- [58] F. Y. Shih. *Image processing and pattern recognition: fundamentals and techniques*. John Wiley & Sons, 2010.
- [59] L. Silva, D. Saade, G. Sequeiros, A. Silva, A. Paiva, R. Bravo, and A. Conci. A new database for breast research with infrared image. *Journal of Medical Imaging and Health Informatics*, 4(1):92–100, 2014.
- [60] L. F. Silva, A. A. S. Santos, R. S. Bravo, A. C. Silva, D. C. Muchaluat-Saade, and A. Conci. Hybrid analysis for indicating patients with breast cancer using temperature time series. *Computer methods and programs in biomedicine*, 130:142–153, 2016.
- [61] J. Tyson. How stuff works, tech. how night vision works. <https://electronics.howstuffworks.com/gadgets/high-tech-gadgets/nightvision.htm>. Accessed: 2018-05-26.
- [62] M. Vollmer, M. Klaus-Peter, et al. *Infrared thermal imaging: fundamentals, research and applications*. John Wiley & Sons, 2017.
- [63] I. H. Witten, E. Frank, M. A. Hall, and C. J. Pal. *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2016.
- [64] Y. J. Zhang. Influence of segmentation over feature measurement. *Pattern Recognition Letters*, 16(2):201–206, 1995.
- [65] Y.-J. Zhang. An overview of image and video segmentation in the last 40 years. *Advances in Image and Video Segmentation*, pages 1–15, 2006.