



INSTITUTO POLITÉCNICO NACIONAL

SECCIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
ESCUELA SUPERIOR DE INGENIERÍA MECÁNICA Y ELÉCTRICA
UNIDAD ZACATENCO

**CLASIFICACIÓN DE MAMOGRAFÍAS USANDO
LA FUNCIÓN DE BASE RADIAL DE RANGO
TIPO M**

TESIS
que para obtener el grado de:

**MAESTRO EN CIENCIAS EN INGENIERÍA
ELECTRÓNICA**

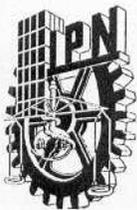
Presenta:
Ing. José Augusto Moreno Escobar

Asesor:
Dr. Francisco Javier Gallegos Funes



México D.F.

Mayo de 2007



INSTITUTO POLITECNICO NACIONAL SECRETARIA DE INVESTIGACION Y POSGRADO

ACTA DE REVISION DE TESIS

En la Ciudad de México, D. F. siendo las 14:00 horas del día 28 del mes de Marzo del 2007 se reunieron los miembros de la Comisión Revisora de Tesis designada por el Colegio de Profesores de Estudios de Posgrado e Investigación de la E. S. I. M. E. para examinar la tesis de grado titulada:

“CLASIFICACIÓN DE MAMOGRAFÍAS USANDO LA FUNCIÓN DE BASE RADIAL DE RANGO TIPO M”

Presentada por el alumno:

MORENO

Apellido paterno

ESCOBAR

Apellido materno

JOSÉ AUGUSTO

Nombre(s)

Con registro:

A	0	5	0	1	5	3
---	---	---	---	---	---	---

Aspirante al grado de:

MAESTRO EN CIENCIAS

Después de intercambiar opiniones los miembros de la Comisión manifestaron **SU APROBACION DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISION REVISORA

Director de tesis

DR. FRANCISCO JAVIER GALLEGOS FUNES

Presidente

DR. ALEXANDRE MICHCHENKO

Segundo Vocal

DR. HÉCTOR MANUEL PÉREZ MEANA

Tercer Vocal

DR. VLADIMIR KAZAKOV ERASOVA

Secretario

DR. JOSÉ MANUEL DE LA ROSA VÁZQUEZ

Suplente

DR. RAÚL PEÑA RIVERO

EL PRESIDENTE DEL COLEGIO

DR. JAIME ROBLES GARCÍA



SECCION DE ESTUDIOS DE
POSGRADO E INVESTIGACION



INSTITUTO POLITECNICO NACIONAL
COORDINACION GENERAL DE POSGRADO E INVESTIGACION

CARTA CESION DE DERECHOS

En la Ciudad de México, Distrito Federal, el día 28 del mes marzo del año 2007, el (la) que suscribe José Augusto Moreno Escobar alumno(a) del Programa de Maestría en Ciencias en Ingeniería Electrónica con número de registro A050153, adscrito a la Sección de Estudios de Posgrado e Investigación de la ESIME Unidad Zacatenco, manifiesta que es autor(a) intelectual del presente Trabajo de Tesis bajo la dirección del Dr. Francisco Javier Gallegos Funes y cede los derechos del trabajo intitulado: Clasificación de Mamografías usando la Función de Base Radial De Rango tipo M, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, graficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección: j.augusto.moreno@gmail.com, fgallegosf@ipn.mx.

Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

JOSÉ AUGUSTO MORENO ESCOBAR

Nombre y firma

DEDICATORIA

A mis padres, José Manuel y Angélica, por que siempre me han apoyado incondicionalmente en cualquier proyecto que he realizado y son mi ejemplo de superación y de amor a seguir

A mis hermanos, Manuel Alejandro y Gélica Valeria por su cariño.

A Nora Luz y Jesús Alberto por formar parte de mi familia.

A Sebastián Alejandro, Ana Sofía y José Alberto.

A Bety, Bobis, Lucero y Nely por haberme abierto las puertas no sólo de su casa, sino también de su hogar.

A Eunice por su gran cariño y soporte a lo largo de esta etapa de mi vida.

A mi gran familia, grande no sólo en número, sino también grande de corazón.



AGRADECIMIENTOS

A mis padres y a toda mi gran familia por su apoyo económico y moral.

Al Dr. Francisco Javier Gallegos Funes por todo el apoyo y la confianza
brindados durante la realización de este trabajo

A todos los profesores de la SEPI que me compartieron sus conocimientos e
hicieron grata mi estancia en la escuela.

Al Instituto Politécnico Nacional por el apoyo económico otorgado durante mis
estudios.

ÍNDICE GENERAL

	Página
RESUMEN	iv
ABSTRACT	v
ÍNDICE DE FIGURAS Y TABLAS	
Figuras	vi
Tablas	viii
NOMENCLATURA	ix
1. INTRODUCCIÓN	
1. 1. Introducción	1
1. 2. Objetivo	2
1. 3. Justificación	2
1. 4. Metas	3
1. 5. Organización de la Tesis	3
1. 6. Referencias	5
2. CÁNCER DE MAMA	
2. 1. Introducción	6
2. 2. Tipos de Cáncer de mama	8
2. 2. 1. Microcalcificaciones	9
2. 3. Tratamiento del Cáncer de mama	9
2. 3. 1. Tipos de cirugía para el cáncer de mama	10
2. 4. Mamografía	10
2. 5. Conclusiones	13
2. 6. Referencias	13
3. SEGMENTACIÓN Y EXTRACCIÓN DE CARACTERÍSTICAS	
3. 1. Introducción	14
3. 2. Segmentación	14
3. 2. 1. Filtros diferenciales	14
3. 2. 2. Detección de bordes	16
3. 2. 2. 1. Cálculo del gradiente	17
3. 2. 3. Morfología	19
3. 2. 3. 1. Suma de Minkowski	19
3. 2. 3. 2. Elementos Estructurales	20
3. 2. 3. 2. Dilatación y Erosión	21
3. 2. 4. Técnica de selección de umbral	24

3.	3.	Extracción de Características	26	
3.	3.	1. Cálculo de magnitudes geométricas	26	
3.	3.	2. Estadística Descriptiva	29	
3.	4.	Conclusiones	31	
3.	5.	Referencias	32	
4.	REDES NEURONALES ARTIFICIALES			
4.	1.	Introducción	33	
4.	2.	Redes Neuronales Biológicas	33	
4.	3.	Redes Neuronales Artificiales	35	
4.	3.	1. Definición	36	
4.	4.	Características principales de las Redes Neuronales Artificiales	37	
4.	4.	1. Estructura básica	37	
4.	4.	2. Fases de la implementación de una red neuronal artificial	38	
4.	4.	3. Clasificación de Redes Neuronales	39	
4.	4.	4. Funciones de activación	40	
4.	4.	5. Algunos modelos de redes neuronales importantes	41	
4.	5.	Conclusiones	42	
4.	6.	Referencias	42	
5.	LA FUNCIÓN DE BASE RADIAL Y LA ESTADÍSTICA DE ORDEN			
5.	1.	Introducción	44	
5.	2.	Función de Base Radial (RBF)	44	
5.	2.	1. Características de la RBF	45	
5.	2.	2. Arquitectura de una RBF	45	
5.	2.	3. Funcionamiento de una RBF	46	
5.	2.	4. Entrenamiento de una RBF	49	
5.	2.	4.	1. Aprendizaje no supervisado	49
5.	2.	4.	2. Aprendizaje supervisado	50
5.	3.	Estadística Robusta	51	
5.	3.	1. Cuantificación de Robustez	52	
5.	3.	1.	1. Punto de ruptura	52
5.	3.	1.	2. Función de Influencia	52
5.	3.	2. Estimadores M	53	
5.	3.	3. Estimador de Rango Tipo M	53	
5.	4.	Conclusiones	53	
5.	5.	Referencias	54	

6. REGIONES DE INTERÉS Y CLASIFICACIÓN DE IMÁGENES DE MAMOGRAFÍA	
6. 1. Introducción	56
6. 2. Regiones de interés	56
6. 3. Datos de Prueba	66
6. 4. Clasificación	72
6. 4. 1. Pruebas del clasificador	72
6. 4. 2. Implementación del clasificador	76
6. 5. Sensitividad y Especificidad	82
6. 5. 1. Sensitividad	82
6. 5. 2. Especificidad	82
6. 6. Tiempos de procesamiento	83
6. 7. Conclusiones	84
6. 8. Referencias	86
7. CONCLUSIONES Y TRABAJO A FUTURO	
7. 1. Conclusiones	88
7. 2. Trabajo a futuro	90
ANEXOS	
Anexo A	Algoritmo de las K-Medias 92
	Referencias 96
Anexo B	Glosario 97
	Referencias 99
Anexo C	Colección de imágenes de mamografía 100
	Referencias 105
Anexo D	Programas en Matlab 106
Anexo E	Publicaciones y Congresos 114

RESUMEN

El uso del Diagnóstico Asistido por Computadora para el análisis de pruebas médicas está tomado relevancia en áreas como ECG y EEG, pero también en la detección de cáncer. En este trabajo se propone la red neuronal Función de Base Radial de Rango tipo M (RMRBF) para la detección de anomalías que puedan producir cáncer de mama. La red neuronal propuesta usa estimadores RM en el esquema del algoritmo de la Red Neuronal tipo Función de Base Radial (RBF) para entrenar la red propuesta. La RMRBF es comparada con otros algoritmos relacionados a la RBF encontrados en la literatura. De los resultados de las simulaciones realizadas se observa que la RMRBF tiene mayor capacidad de clasificación y una eficiencia mayor, de alrededor de un 5%, que los algoritmos usados como comparativo.

ABSTRACT

The use of Computer Aided Diagnosis (CAD) for medical data analysis is taking relevance in areas as ECG and EEG, but also in cancer detection. In this paper we propose the Rank M-Type Radial Basis Function (RMRBF) neural network for the detection of abnormalities that can cause breast cancer. The proposed neural network uses the RM-estimator in the scheme of the Radial Basis Function neural network to train the proposed network. The proposed RMRBF is compared with other RBF based algorithms found in literature. From simulation results we observe that the RMRBF gives better classification capabilities and better efficiency, about a 5%, than the algorithms proposed as comparative.

ÍNDICE DE FIGURAS Y TABLAS

FIGURAS

	Descripción	Página
Figura 2.1	Gráfica que muestra los primeros lugares de incidencia de cáncer en la población de nuestro país.	6
Figura 2.2	Microcalcificación.	9
Figura 2.3	Sistema de mamografía.	11
Figura 2.4	Ejemplos de mamografías.	11
Figura 3.1	Matriz z en la que cada elemento tiene un diferente nivel de gris.	15
Figura 3.2	Operadores de Prewitt.	16
Figura 3.3	Operadores de Sobel.	16
Figura 3.4	Detección de bordes por operadores de derivación.	18
Figura 3.5	Suma de Minkowski.	20
Figura 3.6	Elementos estructurales.	21
Figura 3.7	Operación de dilatación.	22
Figura 3.8	Operación de erosión.	22
Figura 3.9	Imágenes digitales. Imagen de entrada y elemento estructural.	23
Figura 3.10	Operación de dilatación. Imagen después de dilatación.	23
Figura 3.11	Imagen después de la erosión.	23
Figura 3.12	Histogramas de nivel de gris.	25
Figura 3.13	Ejes máximo y mínimo de un objeto.	28
Figura 3.14	Perímetro.	29
Figura 4.1	Neurona y conexiones sinápticas.	34
Figura 4.2	Sinapsis.	35
Figura 4.3	Diagrama básico de una red neuronal artificial.	37
Figura 4.4	Entrenamiento supervisado.	39
Figura 4.5	Entrenamiento no supervisado.	39
Figura 4.6	Red neuronal unidireccional.	39
Figura 4.7	Red neuronal recurrente.	40
Figura 5.1	Capas de una RBF.	46
Figura 5.2	Elementos principales de una Función de Base Radial.	47
Figura 5.3	Funciones de base radial.	48
Figura 5.4	Ajuste de amplitud.	50
Figura 6.1	Diagrama representativo de las etapas de segmentación y extracción de características.	57
Figura 6.2	Elemento estructural usado para delimitar regiones de interés.	58

Figura 6.3	Mamografías de prueba para la etapa de segmentación.	58
Figura 6.4	Objeto detectado en las imágenes de la Figura 6.3 mediante técnicas de segmentación morfológicas.	59
Figura 6.5	Resultados visuales de segmentación de la Figura 6.3(a).	60
Figura 6.6	Resultados visuales de segmentación de la mamografía de la Figura 6.3(b).	61
Figura 6.7	Resultados visuales de segmentación de la mamografía de la Figura 6.3(c)	62
Figura 6.8	Segmentación de la mamografía de la Figura 6.3(b)	64
Figura 6.9	Segmentación de una mamografía de la Figura 6.3(c)	65
Figura 6.10	Segmentación de una mamografía de mayor resolución	66
Figura 6.11	Densidad de objeto.	68
Figura 6.12	Contraste.	68
Figura 6.13	Desviación estándar del objeto.	69
Figura 6.14	Desviación estándar del seno o mama.	69
Figura 6.15	Promedio del objeto.	70
Figura 6.16	Promedio del seno o mama.	70
Figura 6.17	Rango del objeto.	71
Figura 6.18	Rango del seno o mama.	71
Figura 6.19	Diagrama de la RBF implementada.	73
Figura 6.20	Imágenes de prueba.	74
Figura 6.21	Diagrama del entrenamiento de la RBF.	75
Figura 6.22	Eficiencia de la RBF simple.	79
Figura 6.23	Eficiencia de la Median RBF.	79
Figura 6.24	Eficiencia de la α -trimmed mean RBF.	80
Figura 6.25	Eficiencia de la RMRBF (Simple Cut).	80
Figura 6.26	Eficiencia de la RMRBF (Tukey).	81
Figura 6.27	Imagen de mamografía con un resultado correcto.	85
Figura 6.28	Imagen de mamografía con un resultado incorrecto.	86
Figura A1	Conjunto de patrones sobre el que se aplica el algoritmo de las k-medias y resultado de la primera asignación.	94
Figura A2	Segunda y tercera asignaciones.	96

TABLAS

	Descripción	Página
Tabla 2.1	Distribución de neoplasias malignas por topografía en mujeres.	7
Tabla 4.1	Funciones de activación.	41
Tabla 4.2	Principales Redes Neuronales Artificiales.	42
Tabla 6.1	Valores máximos de píxeles de las imágenes de la Figura 6.4.	60
Tabla 6.2	Resultados de segmentación de las mamografías de la Figura 6.3.	63
Tabla 6.3	Entrenamiento de la RBF con formas geométricas sencillas.	74
Tabla 6.4	Prueba de la RBF con formas geométricas sencillas	75
Tabla 6.5	Entrenamiento de la RBF con formas geométricas sencillas.	76
Tabla 6.6	Prueba de la RBF con formas geométricas sencillas.	76
Tabla 6.7	Resultados de rendimiento mediante el uso de diferentes redes neuronales.	78
Tabla 6.8	Resultados de rendimiento en el Grupo 1 y en el Grupo 2.	81
Tabla 6.9	Sensitividad y Especificidad de las Redes Neuronales implementadas.	82
Tabla 6.10	Tiempos de segmentación y extracción de características.	83
Tabla 6.11	Tiempos de clasificación.	83
Tabla 6.12	Porcentajes totales de tiempo (promedio).	83
Tabla 6.13	Porcentaje de mejora en la eficiencia de la RMRBF.	84

NOMENCLATURA

Símbolo	Descripción/Usó General
α	Ángulo de dirección
ϕ_i	Funciones radiales
$\tilde{\psi}$	Función de Influencia Normalizada
μ_k	Estimador MM no iterativo
ω_{ik}	Peso de conexión
σ	Desviación estándar
∞	Infinito
θ	Estimación de la mediana del conjunto inicial de datos
∇f	Gradiente de una función
$\frac{\partial f}{\partial x}$	Derivada parcial de la función f con respecto a la coordenada x
$\frac{\partial f}{\partial y}$	Derivada parcial de la función f con respecto a la coordenada y
A	Conjunto en el espacio euclidiano
a	Elemento perteneciente al conjunto A
b	Elemento perteneciente al conjunto B Elemento Estructural
B	Conjunto en el espacio euclidiano
C	Centro de elemento estructural Centro de una Función de Base Radial
D	Dominio
d_i	Desviación, anchura o dilatación de la Función de Base Radial
f	Función
G_y	Máscara usada en el Procesamiento Digital de Imágenes para calcular la derivada en el sentido horizontal
G_x	Máscara usada en el Procesamiento Digital de Imágenes para calcular la derivada en el sentido vertical
$g(x, y)$	Imagen umbralizada
i	Variable de conteo para la coordenada x
j	Variable de conteo para la coordenada y
m	Neuronas en la capa oculta de una RBF
n	Conjunto de elementos Patrón de entrada a una RBF
p	Neuronas en la entrada de una RBF
$p(x, y)$	Propiedad local de un punto en una imagen

r	Neuronas en la capa de salida de una RBF Constante real
s	Variable de desplazamiento para la coordenada x
t	Variable de desplazamiento para la coordenada y
T	Umbral para la segmentación de imágenes
u	Umbral de la neurona de salida de una RBF
x	Coordenada vertical
x_c	Coordenada x de un centroide
\bar{x}	Media Aritmética
y	Coordenada horizontal
y_c	Coordenada y de un centroide
z	Matriz con diversas tonalidades de gris
$hardli\ m$	Limitador duro
med	Mediana
seg	Píxel de un objeto segmentado

CAPÍTULO 1

INTRODUCCIÓN

1.1 INTRODUCCIÓN

El uso de la Inteligencia Artificial es cada día más común en diversas áreas del conocimiento, ya que es una herramienta que permite el rápido análisis de varios datos mediante algoritmos de fácil implementación en computadora, DSP, microcontrolador, etc. [1,2].

Una de las áreas en las que la Inteligencia Artificial tiene un importante desarrollo es la medicina [3,4,5]. Esto ha dado lugar al surgimiento de los sistemas de Diagnóstico Asistido por Computadora, mejor conocido como CAD (por sus siglas en inglés, *Computer Aided Diagnosis*), los cuales permiten el análisis de muestras médicas de manera rápida y automática [3,4,5]. Aunque la eficiencia de algunos de estos sistemas no es la mejor, varios estudios alrededor del mundo han permitido mejoras que llevan a suponer que en un futuro no muy lejano los Sistemas de Salud de varios países consideren el uso de sistemas de CAD. Cabe señalar que estos sistemas no pretenden sustituir al médico especialista, sino servir como una segunda opinión, que en varios casos, puede ser muy útil.

En la actualidad los sistemas CAD tienen un importante desarrollo en el análisis de señales del corazón (ECG) y señales cerebrales (EEG) [4,6].

La aplicación de los sistemas CAD también tiene algunos desarrollos en la detección de cáncer, principalmente en Inglaterra y Estados Unidos [3]. El objetivo de su uso para este tipo de padecimiento se enfoca en la detección temprana de la enfermedad para poder incrementar las probabilidades de cura del paciente [3,5].

Las RNA tienen el potencial de tener un rendimiento mayor que los algoritmos computacionales tradicionales. Desde el inicio de la década de los 90's se han considerado varias redes neuronales para la detección de cáncer. Conforme se

tenga mayor acceso a pruebas médicas de calidad se va a tener mejor evidencia del potencial de las RNA para ayudar en el difícil problema de la detección de cáncer de mama.

1.2 OBJETIVO

El objetivo de este trabajo es lograr obtener un programa computacional que permita clasificar entre imágenes de mamografías sanas imágenes de mamografía que presenten alguna anormalidad que pueda causar riesgo a la salud mediante el uso de Redes Neuronales Artificiales.

1.3 JUSTIFICACIÓN

Una mamografía es una exploración radiológica de las mamas que sirve para detectar alteraciones del tejido mamario antes de que puedan verse o sentirse, y que en algunas ocasiones son de difícil análisis por lo que el diagnóstico puede complicarse y requerir otro tipo de pruebas médicas, como la biopsia.

Al ser la mamografía la opción de análisis menos incómoda para el paciente, el análisis de este tipo de imágenes mediante algoritmos computacionales puede ser una alternativa de diagnóstico que ofrezca una “opinión” alterna a la del médico especialista. Es por eso que surge la idea de los algoritmos llamados Redes Neuronales Artificiales (RNA) para este propósito, ya que son sistemas de reconocimiento de patrones que pueden generalizar aprendiendo de ejemplos, y son particularmente útiles en problemas donde las reglas para tomar decisiones no son precisas y no hay un conocimiento explícito sobre las funciones de probabilidad que gobiernan la distribución de la muestra [7,8].

1.4 METAS

- Investigar e implementar un método de segmentación que permita una delimitación automática de regiones de interés en imágenes que presentan formas irregulares.
- Investigar e implementar una Red Neuronal Artificial que sea un buen clasificador.
- Comparar los resultados del sistema propuesto con otros métodos existentes mediante la implementación computacional de éstos últimos.
- Mejorar la eficiencia del sistema propuesto mediante la manipulación de los parámetros de la Red Neuronal Artificial.

1.5 ORGANIZACIÓN DE LA TESIS

A continuación se hace una breve descripción del contenido de los capítulos y anexos contenidos en esta tesis.

- Capítulo 1. **Introducción**
- Capítulo 2. **Cáncer de Mama**
Aquí se hace una breve reseña de lo que es el cáncer de mama y se abordan algunos temas como tipos de cáncer de mama, tratamiento, tipos de cirugía y mamografía.
- Capítulo 3. **Segmentación y extracción de características**
Se hace una descripción de los métodos de segmentación empleados en este trabajo y se aborda la parte referente a la extracción de los datos a procesar.
- Capítulo 4. **Redes Neuronales Artificiales**
Se presenta una breve introducción a las Redes Neuronales Artificiales, se hace una comparación de su funcionamiento con el de las redes neuronales biológicas, y se presentan algunas generalidades de estos algoritmos.
- Capítulo 5. **Función de Base Radial y Estadística de Orden.**

Se introduce la Función de Base Radial como clasificador, se describen algunas de sus características y se hace una breve introducción a la Estadística Robusta.

- Capítulo 6. **Regiones de interés y Clasificación de Mamografías**

Aquí se muestra el trabajo experimental de la tesis, y se hace una comparación del método propuesto con otros métodos existentes.

- Capítulo 7. **Conclusiones y Trabajo Futuro**

En esta parte se mencionan las conclusiones obtenidas en este trabajo, y se mencionan algunas alternativas de mejoras al sistema como trabajo a futuro.

- Anexo A. **Algoritmo de las K Medias**

Se da un ejemplo de un algoritmo que fue necesario para lograr implementar la Red Neuronal propuesta.

- Anexo B. **Glosario**

Se muestra el significado de algunos términos encontrados a lo largo de este trabajo.

- Anexo C. **Colección de Imágenes de Mamografía**

Aquí se enlistan las principales imágenes de mamografía empleadas en este trabajo.

- Anexo D. **Programas**

Se muestran los programas desarrollados en Matlab.

- Anexo E. **Congresos**

Se muestran los diplomas obtenidos en diversos congresos por la exposición de los artículos derivados de este trabajo.

1.6 REFERENCIAS

- [1] Pedro Isasi Viñuela, Inés M. Galván León, “Redes Neuronales Artificiales, un enfoque práctico” Pearson-Prentice Hall, 2004. Páginas 1-18.
- [2] Nikola K. Kazabov, “Fundations of Neural Networks, Fuzzy Systems and Knowledge Engineering”. The MIT Press. 1998. Páginas 75-154.
- [3] P.J.G. Lisboa. “A review of evidence of health benefit from artificial neural networks in medical intervention”. School of Computing and Mathematical Sciences, Liverpool John Moores University Liverpool, UK. 2002.
- [4] Silipo R, Marchesi C. “Artificial neural networks for automatic ECG analysis”. IEEE Trans Signal Process 1998;46:1417--25.
- [5] Predrag R. Bakie y Dragana P. Brzakovic, “Application of Neural Networks in Computer Aided Diagnosis of Breast Cancer”. IEEE Transactions on Medical Imaging. 2002.
- [6] Cristina Juárez Landín, “Almacenamiento de señales de EEG y reconstrucción de sus características usando redes neuronales”. Tesis de Maestría. SEPI-ESIME-Culhuacán. Junio del 2003. Páginas 47-59.
- [7] Mario Gómez Martínez, “Teoría y simulación de redes neuronales artificiales”. Universidad Politécnica de Valencia. 1999.
- [8] <http://ohm.edu.co/neuronales/main1.htm>

CAPÍTULO 2

CÁNCER DE MAMA

2.1 INTRODUCCIÓN

El cáncer de mama es un tumor maligno que aparece en cualquier parte de la glándula mamaria [1,2]. Es un cáncer que se extiende a través del sistema linfático (sistema vascular accesorio al sanguíneo), por lo que siempre deben revisarse y en ocasiones extraerse los ganglios de la axila y del cuello para comprobar si el cáncer no se ha extendido. La enfermedad se presenta principalmente en las mujeres, pero los hombres también pueden desarrollarla. El cáncer de mama es el segundo más frecuente en México después del de cuello de la matriz o cáncer cervical. En la Figura 2.1 se muestran los 6 tipos de cáncer de mayor incidencia en México, los cuales ocupan un poco más del 70% de las incidencias de cáncer en nuestro país [3].

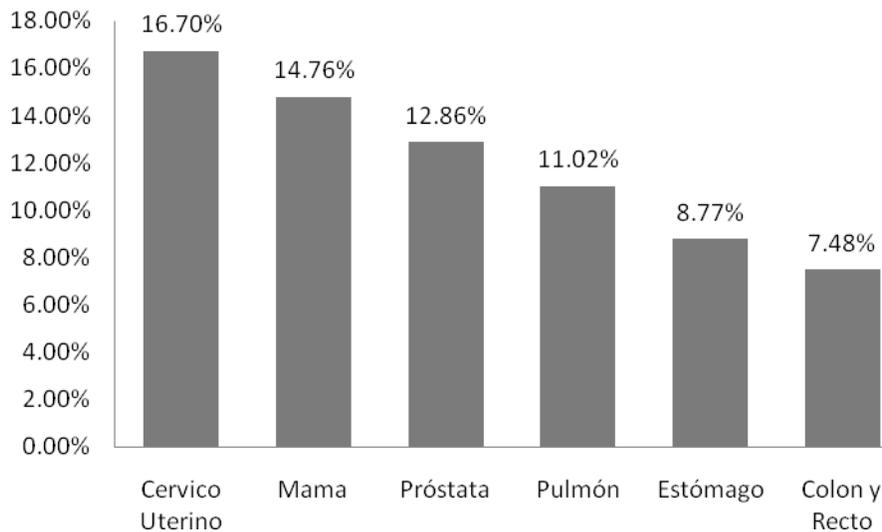


Figura 2.1. Gráfica que muestra los primeros lugares de incidencia de cáncer en la población de nuestro país [3].

El cáncer de mama suele comenzar con una alteración a nivel celular que puede ser causada por diversos factores: tipo de dieta, tabaquismo, exposición solar, ciertas sustancias, radiaciones, etc. [2]. En el desarrollo de este tipo de cáncer influyen directamente aspectos hereditarios, uso prolongado de anticonceptivos orales, temprano inicio de la menstruación, obesidad posmenopáusica o ausencia de embarazos [1,2].

En la Tabla 2.1 se pueden apreciar las 10 neoplasias más frecuentes en la población del sexo femenino en nuestro país [3].

Tabla 2.1. Distribución de neoplasias malignas por topografía en mujeres [3].

Lugar	Localización	No.	%
1	Cuello del Útero	12,516	23.09
2	Mama	11,064	20.41
3	Estómago	3785	6.98
4	Ovario	3137	5.79
5	Colon y Recto	2814	5.19
6	Pulmón	2633	4.86
7	Tiroides	2475	4.57
8	Leucemia	2151	3.97
9	Hígado	1928	3.56
10	Cuerpo del Útero	1703	3.14

Para el caso del cáncer de mama, en el año 2002 fallecieron 4310 mujeres en México a causa de este mal, que representó el 14.38% del total de fallecimientos por cáncer de la población femenina en México [3].

El crecimiento y extensión del cáncer de mama depende del tipo de células malignas que lo compongan. También hay una gran variación en la tendencia a ramificarse que tiene este tumor. Las probabilidades de curación no son tan altas en etapas avanzadas de la enfermedad; aun así, con los tratamientos actuales, existen buenas posibilidades de supervivencia. Esta enfermedad es fatal si no se trata a tiempo. Es extremadamente importante que se realice un diagnóstico temprano. En ausencia de una efectiva prevención, el diagnóstico precoz es un importante medio para reducir la mortalidad [1,2,4]

2.2 TIPOS DE CÁNCER DE MAMA

El cáncer de mama se clasifica en 5 tipos diferentes [4,5]:

1. *El carcinoma ductal in situ* se origina en las células de las paredes de los conductos mamarios. Es un cáncer muy localizado, que no se ha extendido a otras zonas ni ha producido metástasis. Por este motivo esta enfermedad 'pre maligna' puede extirparse fácilmente. La tasa de curación ronda el 100%. Este tipo de tumor se puede detectar a través de una mamografía.
2. *El carcinoma ductal infiltrante* (o invasivo) es el que se inicia en el conducto mamario pero logra atravesarlo y pasa al tejido adiposo de la mama y luego puede extenderse a otras partes del cuerpo. Es el más frecuente de los carcinomas de mama, se da en el 80% de los casos.
3. *El carcinoma lobular in situ* se origina en las glándulas mamarias (o lóbulos) y, aunque no es un verdadero cáncer, aumenta el riesgo de que la mujer pueda desarrollar un tumor canceroso en el futuro. Se suele dar antes de la menopausia. Una vez que es detectado, es importante que la mujer se realice una mamografía de control al año y varios exámenes clínicos para vigilar el posible desarrollo de cáncer.
4. *El carcinoma lobular infiltrante* (o invasivo) comienza en las glándulas mamarias pero se puede extender y destruir otros tejidos del cuerpo. Entre el 10% y el 15% de los tumores de mama son de este tipo. Este carcinoma es más difícil de detectar a través de una mamografía.
5. *El carcinoma inflamatorio* es un cáncer poco común, tan sólo representa un 1% del total de los tumores cancerosos de la mama. Es agresivo y de rápido crecimiento. Hace enrojecer la piel del seno y aumentar su temperatura. La apariencia de la piel se vuelve gruesa y ahuecada, como la de una naranja, y pueden aparecer arrugas y protuberancias. Estos síntomas se deben al bloqueo que producen las células cancerosas sobre los vasos linfáticos.

2.2.1 MICROCALCIFICACIONES

Las microcalcificaciones son pequeñas acumulaciones de calcio de 0.1 mm a 2 mm de ancho (ver Figura 2.2), ellos son indicadores favorables de presencia de cáncer de mama, tienen probada capacidad para detectar estadios tempranos de la enfermedad [6].



Figura 2.2. Microcalcificación [7].

2.3 TRATAMIENTO DEL CÁNCER DE MAMA

En el tratamiento del cáncer de mama se utilizan cuatro tipos de tratamientos [1,2,4]:

- Cirugía
- Radioterapia
- Quimioterapia
- Terapia hormonal

Se están realizando estudios clínicos con terapia biológica y con el trasplante de medula ósea.

En primer lugar se utiliza la cirugía para extraer el nódulo canceroso de la mama, también se extraen los ganglios linfáticos axilares para su análisis en el microscopio y detectar la extensión de células cancerosas.

2.3.1 TIPOS DE CIRUGÍA PARA EL CÁNCER DE MAMA

Los tipos de cirugía usados contra el cáncer de mama se muestran a continuación [1]:

- Cirugía conservadora:
 - Lumpectomía, que consiste en la extracción del tumor canceroso y una zona de seguridad a su alrededor y en ocasiones algún ganglio axilar. Se asocia posteriormente con la radioterapia.
 - Mastectomía parcial, en ella se extrae el cáncer con parte del tejido de alrededor del mismo y el recubrimiento de los músculos del tórax debajo del tumor, con los ganglios linfáticos axilares. También se aplica posteriormente la radioterapia.
- Cirugía agresiva o radical
 - Mastectomía radical es la extracción de toda la mama y el recubrimiento de los músculos del tórax y de la pared torácica situados debajo del tumor, incluidos los ganglios linfáticos axilares. En la mastectomía *parcial modificada* parte de los músculos de la pared del tórax se conservan.

La radioterapia puede ser externa o a través de radioisótopos aplicados localmente (radioterapia interna) [1], la quimioterapia se aplica de forma intravenosa [1], y finalmente, la terapia hormonal se aplica si las células cancerosas analizadas tienen receptores para estrógenos o progesterona [1].

2.4 MAMOGRAFÍA

La mamografía es un método para examinar los senos o mamas que utiliza pequeñas dosis de radiación mediante el uso de una unidad de mamografía digital como la mostrada en la Figura 2.3. Este simple procedimiento sirve para detectar tumores y quistes muy pequeños, imposibles de descubrir con un examen manual [8]. En algunos casos puede ayudar a determinar la naturaleza del tumor: benigno o maligno (ver Figura 2.4).

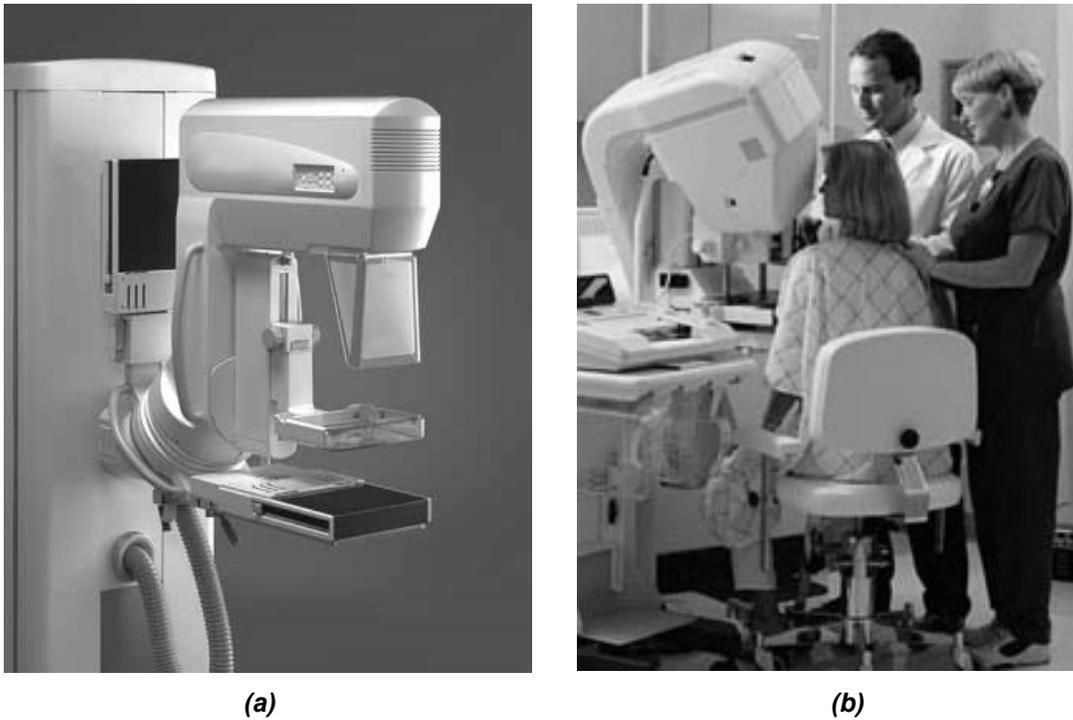


Figura 2.3. Sistema de mamografía, a) Unidad de mamografía digital, b) Mujer a la que se le está tomando una mamografía.

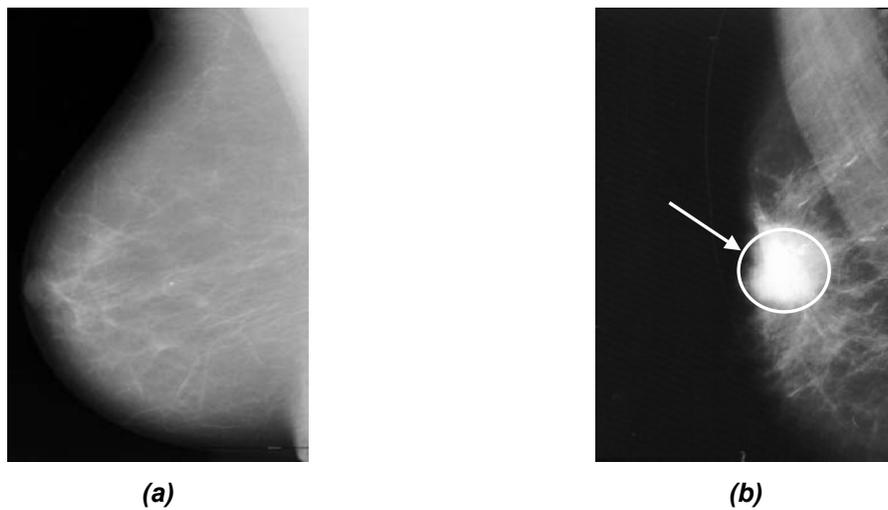


Figura 2.4. Ejemplos de mamografías: (a) No presenta anomalías; (b) Se aprecia la presencia de un tumor [9].

Existen dos tipos de mamografías [1,4,5]: de control (procedimiento de rutina) o de diagnóstico (para examinar áreas específicas en las que se ha palpado un bulto). En mujeres jóvenes, embarazadas o que estén amamantando las mamas

son más densas y la interpretación de la mamografía suele ser más complicada que en mujeres mayores cuyas mamas tienen alta proporción de grasa. Se recurre a las ecografías para distinguir entre masas sólidas, que podrían ser cancerosas, de quistes (bolsas que contienen líquido) que son usualmente no cancerosos y así reducir el número de biopsias innecesarias. La resonancia magnética puede identificar ciertos tumores raros de detectar en mamografías. Para confirmar un diagnóstico de cáncer de mama se realiza una biopsia.

En la actualidad, las 4 técnicas más recientes que se han desarrollado en el área de las mamografías son [1,4,5]: la mamografía de alta resolución, la magnificación, la mamografía digitalizada y la estereotaxia.

La mamografía de alta resolución mediante foco fino de 0,3 y 0,1 mm., permite determinar lesiones del orden de fracciones de milímetros con gran sensibilidad y contraste.

La magnificación, es una técnica que permite aumentar el tamaño de la imagen, pudiéndose estudiar convenientemente la morfología de la misma, con más elementos de juicio a la hora de determinar diagnósticos más precoces.

La estereotaxia es una técnica radiológica que permite dirigir una aguja mediante un microcomputador a un sector de la mama, pudiéndose efectuar su punción para extracción de material celular, evitando así biopsias innecesarias y lesiones.

La mamografía digitalizada es una técnica de estudio de la imagen radiológica de alta definición, que permite descomponer la imagen en diferentes densidades, pudiéndose estudiar estas imágenes en diferentes escalas de colores, imperceptibles al ojo humano y extraer información de alta calidad de zonas que inicialmente pueden ser dudosas, para su correcta catalogación y estudio.

La mamografía de las dos mamas dura como máximo media hora, a no ser que las imágenes obtenidas, a juicio del radiólogo, no sean de buena calidad, en cuyo caso el proceso debe repetirse.

Actualmente, algunas compañías como General Electric, Canon y Emsor, han lanzado al mercado sistemas para obtener mamografías digitalizadas [10,11].

2.5 CONCLUSIONES

La detección del cáncer de mama en etapas tempranas es muy importante, pues de esto depende en gran medida la vida de la persona que tenga este padecimiento. Un método muy común para examinar los senos es la mamografía, la cual permite detectar tumores o quistes muy pequeños.

El cáncer de mama es uno de las causas de muerte más importantes en la población femenina de nuestro país, incluso existen muchas campañas a nivel nacional para generar conciencia de lo importante que es este mal. En este capítulo se hizo una breve descripción de este cáncer, de sus tipos, y de los tratamientos más comunes que existen.

2.6 REFERENCIAS

- [1] www.tuotromedico.com/tema/cancer_de_mama.php
- [2] www.educacionmedica.com.mx
- [3] Globocan 2002. Cancer Incidence, Mortality and Prevalence Worldwide. www.globocan.com
- [4] <http://www.maypo.com.mx/especial/oncologia/service/patol.html>
- [5] <http://www.elmundo.es/elmundosalud/especiales/cancer/>
- [6] Samuel Oporto, Rolando Hernández, Hugo Terashima, “Detección de Microcalcificaciones en Imágenes de Mamografías Usando Diferencia de Filtros Gaussianos Optimizados”. XXX Conferencia Latinoamericana de Informática CLEI 2004.
- [7] <http://members.tripod.com/~gineco>
- [8] <http://www.tusalud.com.mx/130106.htm>
- [9] www.opolanco.es
- [10] <http://www.gehealthcare.com/inen/>
- [11] <http://www.gba-rayosx.com.ar>

CAPÍTULO 3

SEGMENTACIÓN Y EXTRACCIÓN DE CARACTERÍSTICAS

3.1 INTRODUCCIÓN

La segmentación la cual es el primer paso en el análisis automático de imágenes. Esta permite dividir la imagen en partes o regiones en las que se encuentran los datos relevantes que proporcionan la información necesaria para su análisis o descripción. Una vez que se tiene segmentada la imagen, se deben de extraer características de las regiones de interés que permitan su representación y su descripción.

3.2 SEGMENTACIÓN

La segmentación es la parte del análisis de imágenes que consiste en subdividir una imagen en sus partes constituyentes u objetos. El nivel al que se lleva a cabo esta subdivisión depende del problema a resolver; esto es, la segmentación deberá detenerse cuando los objetos de interés de una aplicación hayan sido aislados o delimitados.

En general, la segmentación es una de las tareas más difíciles del procesamiento de imágenes. Esta etapa del proceso determina el eventual éxito o fracaso del análisis.

3.2.1 FILTROS DIFERENCIALES

Al hacer la diferenciación de una imagen aumentamos su nitidez, es decir, se “marcan” mejor los detalles que contiene [1]. El método más común de diferenciación para aplicaciones de procesado de imágenes es el gradiente.

Para una función $f(x, y)$, el gradiente de f en el punto de coordenadas (x, y) se define como el vector [1],

$$\nabla f = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (3.1)$$

El módulo del vector (3.1) esta dado por,

$$\nabla f = \text{mag}(\nabla f) = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} \quad (3.2)$$

Considérese la Figura 3.1, en la que los diferentes subíndices de la variable z tienen diferentes valores de gris. La ecuación (3.2) puede aproximarse alrededor del punto z_5 de distintas formas. Para el caso de una matriz 3x3 se tiene [1]:

$$\begin{aligned} \nabla f \approx & |(z_7 + z_8 + z_9) - (z_1 + z_2 + z_3)| \\ & + |(z_3 + z_6 + z_9) - (z_1 + z_4 + z_7)| \end{aligned} \quad (3.3)$$

La diferencia entre la tercera y la primera fila de la región 3x3 da una aproximación de la derivada en la dirección x , y la diferencia entre la tercera y la primera columna da una aproximación de la derivada en la dirección de y . Las matrices como la de la Figura 3.1 son conocidas como máscaras en el procesamiento digital de imágenes. Las máscaras que se muestran en la Figura 3.2 son los operadores Prewitt [1,2], que pueden emplearse para implementar la ecuación (3.3). La Figura 3.3 muestra los operadores Sobel [1,2], que pueden emplearse para calcular el módulo del gradiente.

z_1	z_2	z_3
z_4	z_5	z_6
z_7	z_8	z_9

Figura 3.1. Matriz z en la que cada elemento tiene un diferente nivel de gris.

Los operadores Sobel y Prewitt emplean 2 máscaras cada uno: una máscara para calcular la derivada en el sentido horizontal (G_y) y otra para calcular la derivada en sentido vertical (G_x). Obsérvese que la suma de todos los coeficientes de una máscara es igual a cero, indicando una respuesta cero en las áreas constantes.

1	1	1
0	0	0
-1	-1	-1

(a)

-1	0	1
-1	0	1
-1	0	1

(b)

Figura 3.2. Operadores de Prewitt para calcular (a) G_y y (b) G_x .

-1	-2	-1
0	0	0
1	2	1

(a)

-1	0	1
-2	0	2
-1	0	1

(b)

Figura 3.3. Operadores de Sobel para calcular (a) G_y y (b) G_x .

3.2.2 DETECCIÓN DE BORDES

Un borde es la frontera entre dos regiones con propiedades de nivel de gris relativamente distintas.

La detección de bordes es un método común para la detección de discontinuidades en imágenes con nivel de gris [1].

La mayor parte de las técnicas de detección de bordes se hace mediante un operador local de derivación (ver Figura 3.4). La Figura 3.4(a) muestra una

imagen de una banda clara sobre un fondo oscuro, el perfil de gris a lo largo de la línea de exploración de la imagen, y la primer y segunda derivada de ese perfil. Se observa en el perfil que un borde (la transición del obscuro al claro) está modelado con un cambio suave, no brusco, de nivel de gris. Este modelo refleja el hecho de que los bordes de las imágenes digitales están en general ligeramente emborronados a causa del muestreo.

La Figura 3.4(b) muestra que la primera derivada del perfil de nivel de gris es positiva en el borde de salida y cero en las zonas de nivel de gris constante. La segunda derivada es positiva en la parte de la transición asociada con el lado oscuro del borde, negativa en la parte de la parte asociada con el lado claro y cero en las zonas de nivel de gris constante. Es por eso que el módulo de la primera derivada se puede utilizar para detectar la presencia de un borde y el signo de la segunda derivada para determinar si un píxel borde está situado en el lado claro u oscuro del mismo.

3.2.2.1 CÁLCULO DEL GRADIENTE

El concepto de gradiente es muy importante en la diferenciación de imágenes, como se vio en la sección 3.2.1. Reescribiendo la ecuación (3.1), el gradiente de una imagen $f(x, y)$ en la posición (x, y) se puede obtener como el vector,

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (3.4)$$

El gradiente de un vector indica la dirección de la máxima variación de f en (x, y) . Una importante cantidad es el módulo de este vector, que se obtiene reescribiendo la ecuación (3.2).

$$\nabla f = \text{mag}(\nabla f) = \sqrt{G_x^2 + G_y^2} \quad (3.5)$$

La cantidad que se obtiene en la ecuación (3.5) es igual a la máxima variación de $f(x, y)$ por unidad de distancia en la dirección de ∇f . En el procesamiento digital de señales, es común aproximar el gradiente por sus valores absolutos [1]:

$$\nabla f \approx |G_x| + |G_y| \quad (3.6)$$

que se pueden implementar con las máscaras para procesamiento digital de imágenes vistas en la sección 3.2.1.

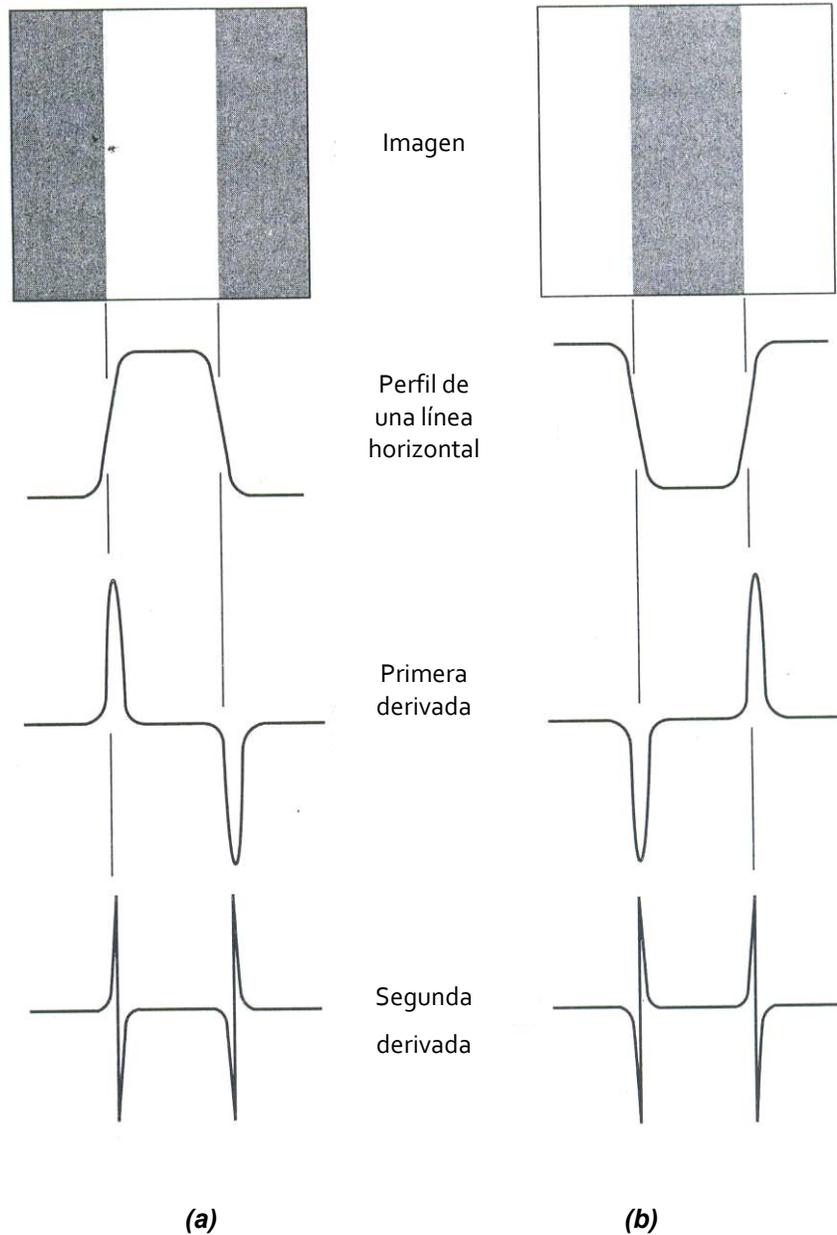


Figura 3.4. Detección de bordes por operadores de derivación. (a) Banda clara sobre fondo oscuro; (b) Banda oscura sobre fondo claro. Se puede observar que la segunda derivada tiene un cruce por cero en la posición de cada borde.

La dirección del vector gradiente es también una cantidad importante. Sea $\alpha(x, y)$ la representación del ángulo de dirección del vector ∇f en (x, y) , entonces la dirección del vector gradiente es [1],

$$\alpha(x, y) = \tan^{-1} \left(\frac{G_x}{G_y} \right) \quad (3.7)$$

donde el ángulo se mide con respecto al eje x .

De las ecuaciones (3.4) y (3.5) se deduce que el cálculo del gradiente de una imagen se basa en la obtención de las derivadas parciales $\frac{\partial f}{\partial x}$ y $\frac{\partial f}{\partial y}$ en cada posición de píxel. Las derivadas se pueden implementar usando las máscaras de Sobel y de Prewitt, que se pueden ver en las Figuras 3.2 y 3.3.

3.2.3 MORFOLOGÍA

La palabra morfología indica normalmente una rama de la biología que trata de la forma y estructura de animales y plantas. Se utiliza aquí la misma palabra en el contexto de la morfología matemática como una herramienta para extraer componentes de una imagen que sean útiles para la representación y la descripción de la forma de una región [1].

3.2.3.1 SUMA DE MINKOWSKI

En geometría, la suma de Minkowski de dos conjuntos A y B en un espacio euclidiano (espacio plano) es el resultado de la suma de cada elemento de A con cada elemento de B [1,3]:

$$A + B = \{a + b \mid a \in A, b \in B\} \quad (3.8)$$

Por ejemplo, si se tienen dos triángulos A y B representados por los puntos $A = \{(1,0), (0,1), (0,-1)\}$ y $B = \{(0,0), (1,1), (1,-1)\}$. Entonces la suma de Minkowski es $A + B = \{(1,0), (2,1), (2,-1), (0,1), (1,2), (1,0), (0,-1), (1,0), (1,-2)\}$, que gráficamente se ve como un hexágono con 3 puntos 'repetidos' en $(1,0)$ como se muestra en la Figura 3.5. Esto define la operación binaria llamada suma de Minkowski. La

suma de Minkowski también es conocida como la dilatación de A por B , y ésta juega un rol central en el procesamiento morfológico de imágenes [1,3].

3.2.3.2 ELEMENTOS ESTRUCTURALES

Una parte esencial de las operaciones morfológicas empleadas son los elementos estructurales [4].

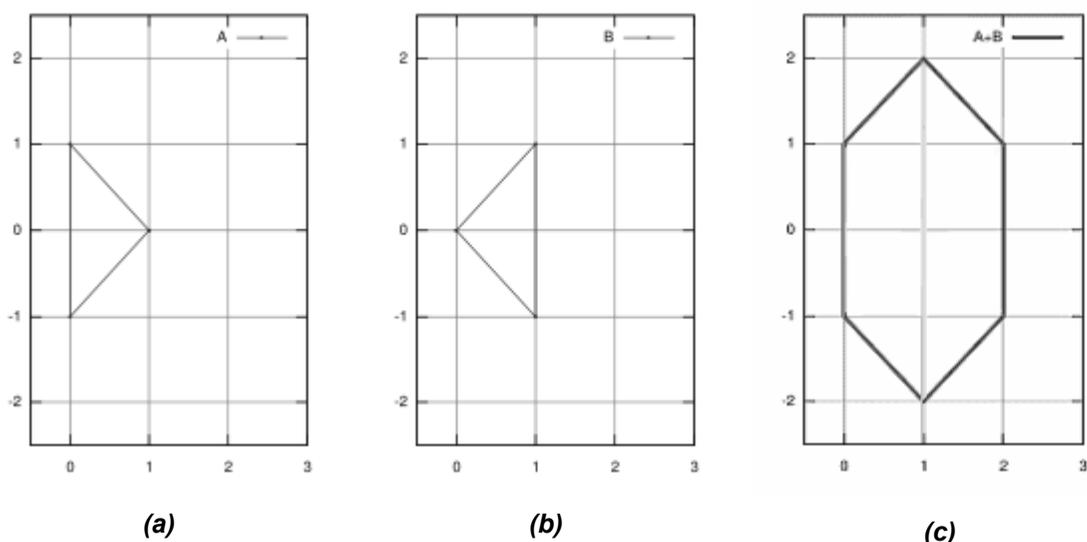


Figura 3.5. Suma de Minkowski. Los conjuntos de puntos A (a) y B (b) se suman de acuerdo a (3.8) y se obtiene el resultado mostrado en (c).

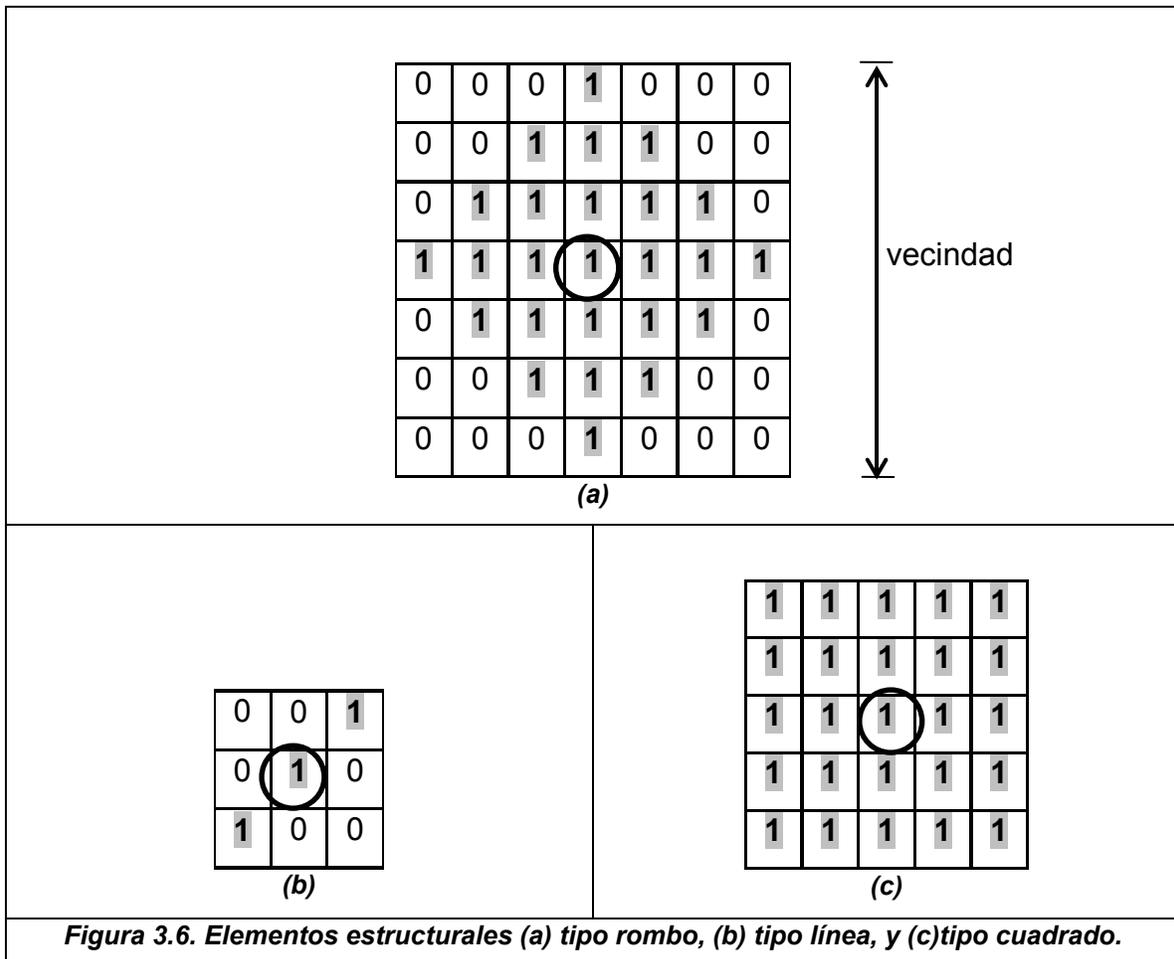
Los elementos estructurales son matrices que se constituyen principalmente con coeficientes (o píxeles) 1's y 0's, y son generalmente mucho más pequeños que la imagen que se va a procesar con técnicas morfológicas. El centro del elemento estructural, representa el píxel de interés (píxel a ser procesado). Los demás coeficientes o píxeles definen la vecindad del elemento estructural. La vecindad se refiere al tamaño del elemento estructural, y por lo general es un número impar.

Para determinar el centro de un elemento estructural se puede usar la siguiente fórmula [4]:

$$C = \text{redondeo hacia abajo}(\text{tamaño}(\text{vecindad}) + 1/2) \quad (3.9)$$

Existen varios tipos de elementos estructurales [2,4]. Por ejemplo, en la Figura 3.6(a) se muestra un rombo (diamante) que tiene una vecindad de 7, cuya

delimitación se muestra en la misma figura. En la figura 3.6(b) se muestra el elemento estructural tipo línea con una vecindad de 3; y en la figura 3.6(c) se muestra un elemento cuadrado con una vecindad de 5, en cada una de las figuras se muestra el centro del elemento, que se puede corroborar con la ecuación (3.9). Cabe señalar que existen otras formas, como círculos, rectángulos, octágonos, etc.



3.2.3.3 DILATACIÓN Y EROSIÓN

Dos de las principales técnicas morfológicas son la dilatación y la erosión [1,2]. Básicamente la dilatación, definida para dos conjuntos A y B como $A \oplus B$ (ver Figura 3.7), consiste en agrandar o expandir una región de interés de una imagen, mientras que la erosión, definida para el mismo par de conjuntos como $A \ominus B$ (ver Figura 3.8), se usa para lo contrario, es decir, para contraer.

Sea f una imagen de entrada y b un elemento estructural tal como se muestra en la Figura 3.9. La dilatación de f por b se representa por $f \oplus b$, y se define como [5]:

$$(f \oplus b)(s,t) = \max\{f(s-x, t-y) + b(x,y) \mid (s-x), (t-y) \in D_f; (x,y) \in (D_b)\} \quad (3.10)$$

donde D_f y D_b son dominios de f y b , respectivamente. Los parámetros de desplazamiento $(s-x)$ y $(t-y)$ deben estar contenidos en el dominio de f , ya que la imagen y el elemento de estructura deben de solaparse en al menos un elemento. La dilatación se puede apreciar gráficamente en la Figura 3.10.

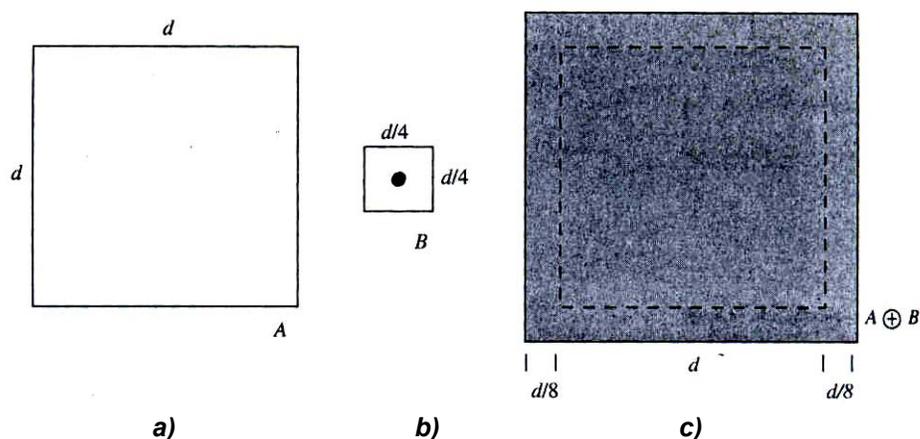


Figura 3.7. Operación de dilatación. Es este caso la imagen A (a) es dilatada usando el elemento estructural B, cuyo centro se puede observar en la figura (b); en (c) se muestra el resultado obtenido.

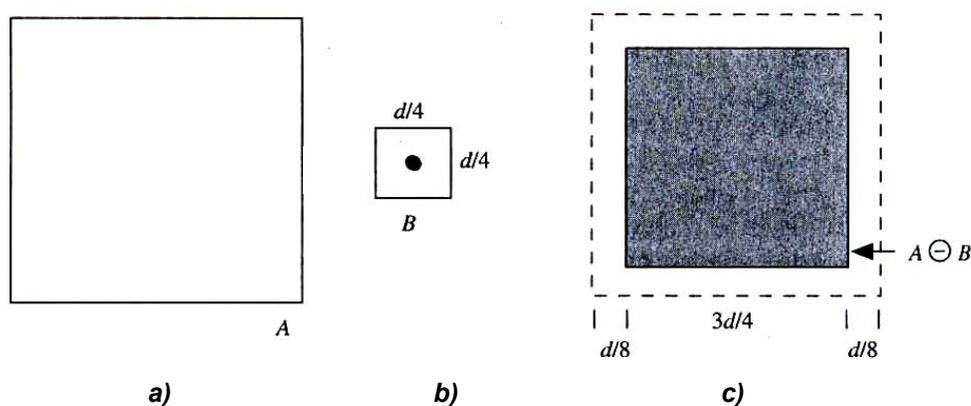


Figura 3.8. Operación de erosión. Es este caso la imagen A (a) es erosionada usando el elemento estructural B (b); en (c) se aprecia el resultado obtenido.

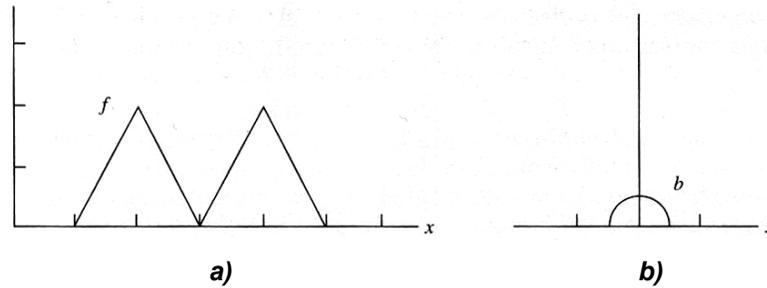


Figura 3.9. Imágenes digitales. (a) Imagen de entrada; (b) Elemento estructural.

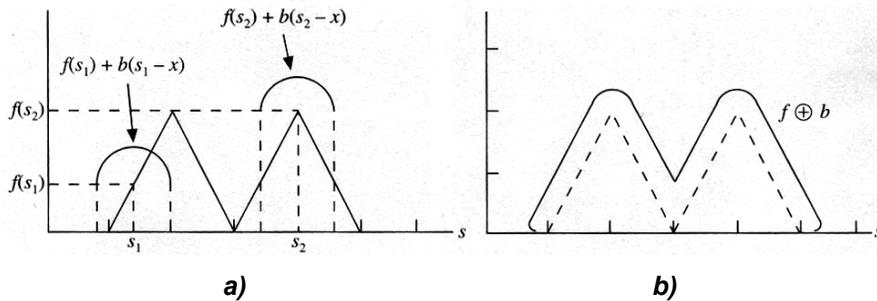


Figura 3.10. (a) Operación de dilatación; (b) Imagen después de la dilatación.

Teniendo en cuenta las imágenes de la Figura 3.9, la erosión se define como [1]:

$$(f \ominus b)(s, t) = \max \{ f(s - x, t - y) + b(x, y) \mid (s - x), (t - y) \in D_f; (x, y) \in D_b \} \quad (3.11)$$

donde al igual que en la ecuación (3.10) D_f y D_b son dominios de f y b respectivamente. Los parámetros de desplazamiento $(s + x)$ y $(t + y)$ deben estar contenidos en el dominio de f , ya que el elemento estructural debe estar completamente contenido en la imagen a erosionar. La erosión se puede apreciar gráficamente en la Figura 3.11.

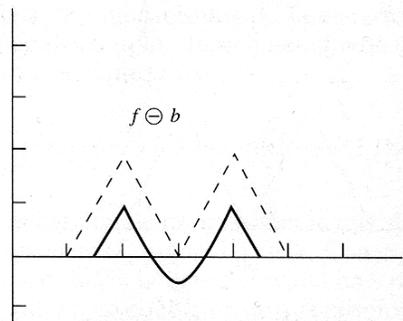


Figura 3.11. Imagen después de la erosión.

Usado estas técnicas morfológicas se pueden realizar las siguientes operaciones [1]:

- Apertura, que generalmente suaviza el contorno de una imagen, rompe istmos estrechos y elimina protuberancias delgadas. La apertura de la imagen de f por el elemento de estructura b se representa por:

$$f \circ b = (f \ominus b) \oplus b \quad (3.12)$$

- Cierre, que también tiende a suavizar contornos pero generalmente fusiona separaciones estrechas y entrantes delgados y profundos. El cierre de f por b se representa por:

$$f \bullet b = (f \oplus b) \ominus b \quad (3.13)$$

- Relleno de regiones, se basa en dilataciones, complementos e intersecciones condicionales.

3.2.4 TÉCNICA DE SELECCIÓN DE UMBRAL

La técnica de selección de umbral es uno de los métodos más importantes de la segmentación de imágenes [1]. Sus fundamentos se comentan a continuación.

Supóngase que el histograma de nivel de gris de la Figura 3.12(a) corresponde a una imagen $f(x, y)$, compuesta de objetos luminosos sobre un fondo oscuro, de tal forma que los píxeles del objeto y el fondo tienen los niveles de gris agrupados en dos modos dominantes. Una forma evidente de extraer los objetos del fondo es escoger un umbral T que separe dichos modos. Entonces, cualquier punto (x, y) para el que $f(x, y) > T$ se denomina punto del objeto; en caso contrario, se denomina punto del fondo. La Figura 3.12(b) muestra un caso ligeramente más general de esta aproximación. Aquí, los tres modos dominantes caracterizan el histograma de la imagen (por ejemplo, dos tipos de objetos claros sobre un fondo oscuro). La misma aproximación básica clasifica un punto (x, y) como integrante de uno de los objetos si $T_1 < f(x, y) \leq T_2$, a la otra clase de objetos si $f(x, y) > T_2$ y al fondo si $f(x, y) \leq T_1$. Este tipo de técnica de umbral, suele ser menos segura que su contrapartida del umbral único. La razón es la

dificultad de establecer umbrales múltiples que aislen efectivamente las regiones de interés, sobre todo cuando el número de modos de los histogramas correspondientes es grande. Normalmente, los problemas de esta naturaleza, si se tratan por técnicas de umbral, se pueden estudiar de una mejor manera por un umbral único que por uno variable.

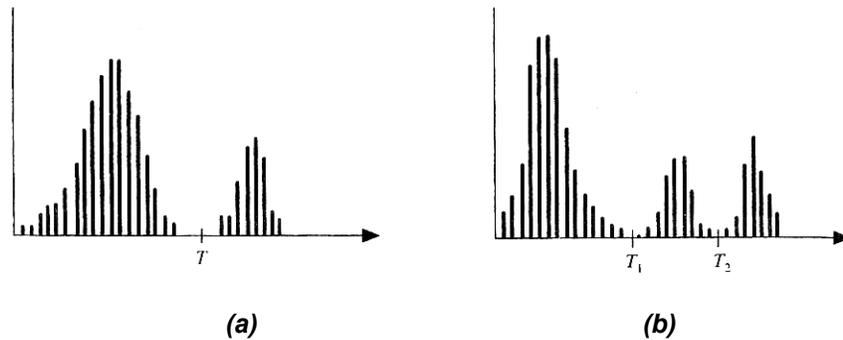


Figura 3.12. Histogramas de nivel de gris que se pueden dividir en: (a) un umbral sencillo, y (b) umbrales múltiples.

La técnica de umbral se puede contemplar como una operación que implica realizar comprobaciones frente a una función T de la forma [1]:

$$T = T[x, y, p(x, y), f(x, y)] \quad (3.14)$$

donde $f(x, y)$ es el nivel de gris del punto (x, y) , y $p(x, y)$ representa alguna propiedad local de ese punto, por ejemplo, la media del nivel de gris de una vecindada centrada en (x, y) . Una imagen umbralizada $g(x, y)$ se define como [1]:

$$g(x, y) = \begin{cases} 0 & \text{si } f(x, y) > T \\ 1 & \text{si } f(x, y) \leq T \end{cases} \quad (3.15)$$

De este modo los píxeles marcados con 1 (o con cualquier otro nivel de intensidad conveniente) corresponden a los objetos, mientras que los píxeles marcados con cero corresponden al fondo.

Cuando T depende solamente de la función $f(x, y)$, el umbral se denomina global. Si T depende a la vez de $f(x, y)$ y $p(x, y)$, el umbral se denomina local.

Si, además, T depende de las coordenadas espaciales x y y , el umbral se denomina dinámico.

3.3 EXTRACCIÓN DE CARACTERÍSTICAS

Una vez que se tiene segmentada la imagen, se deben de extraer características de las regiones de interés que permitan su representación y su descripción.

3.3.1 CALCULO DE LAS MAGNITUDES GEOMETRICAS

En procesamiento de imágenes, el cálculo de magnitudes geométricas se refiere a la evaluación de características asociadas con objetos extraídos de imágenes [5]. Estas mediciones deben de ser usadas para clasificar objetos, ya sea con propósitos de reconocimiento de patrones o para elaborar una base de datos. Estos algoritmos son aplicados en imágenes médicas para la evaluación de tumores, estructuras celulares, y tejidos fetales. La medición de objetos en las imágenes está relacionada con el procesamiento gráfico, donde los límites y los objetos son determinados por un usuario de manera manual, aunque también se usa cuando los objetos son delimitados previamente mediante un método de segmentación.

Las mediciones de la distribución espacial de los píxeles y de sus valores son las más simples de implementar. Algunas cantidades que se pueden considerar como medidas geométricas en una imagen son [5,6]:

- Área.- Los algoritmos de área miden el número de píxeles que se encuentran dentro de un objeto en una imagen. Se debe de definir el límite del objeto, o la región en donde se encuentra el objeto así como el rango de valores de píxel que se deberán de contar como parte de ese objeto.

$$\text{área} = \sum_{i=1}^N \sum_{j=1}^M \text{seg}(i, j) \quad (3.16)$$

donde $\text{seg}(i, j)$ es un píxel del objeto segmentado.

- Centroide.- El centroide se refiere a la ubicación del centro geográfico de un objeto. El centroide se expresa en coordenadas y se calcula usando la expresión:

$$x_c = \frac{1}{\text{área}} \sum_{i=1}^N x \qquad y_c = \frac{1}{\text{área}} \sum_{i=1}^N y \qquad (3.17)$$

donde X_c y Y_c son las coordenadas del centroide, x y y son las coordenadas del i -ésimo píxel.

- Circularidad.- Es una medida de qué tan circular es un objeto.
- Agrupamiento.- Es el proceso de contar y etiquetar objetos dentro de una imagen. Los grupos o *clusters* que se obtienen mediante el agrupamiento están constituidos por píxeles y están relacionados entre sí por una característica dada.
- Densidad de objeto¹.- Es una medida de la distribución de un objeto, y se define como el cuadrado del perímetro dividido entre el área,

$$\text{densidad de objeto} = \frac{\text{perímetro}^2}{\text{área}} \qquad (3.18)$$

- Eje máximo.- el eje máximo de un objeto es formalmente definido como el eje de mínima inercia (dispersión) que pasa a través de su centroide (ver Figura 3.13). En algunas referencias bibliográficas se conoce al eje máximo como eje principal.
- Eje mínimo.- el eje mínimo de un objeto es formalmente definido como el eje de mínima inercia (dispersión) que pasa a través de su centroide (ver Figura 3.13).

¹ El término encontrado en inglés es “compactness”, cuya traducción es densidad, solidez, estrechez [9]. Para el propósito de este trabajo, se optó por traducir “compactness” como densidad de objeto.

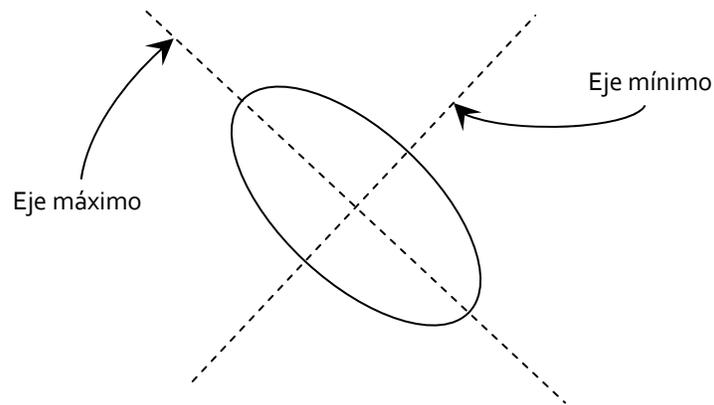


Figura 3.13. Ejes máximo y mínimo de un objeto.

- Momentos.- La geometría de una región plana se basa en el tamaño, la posición, la orientación y la forma. Todas estas medidas están relacionadas con los parámetros denominados momentos. Los momentos son cantidades escalares que proveen de excelentes medidas para análisis de patrones con propósitos de reconocimiento de objetos. Los momentos invariantes de Hu consiguen una buena descripción independiente a las posiciones, tamaños y ángulos del objeto [7].
- Perímetro.- El perímetro es el número de píxeles que encuentran el borde de un objeto. El perímetro de un objeto se puede obtener usando técnicas de detección de bordes descritas anteriormente, un ejemplo de esta medida geométrica se muestra en la Figura 3.14.

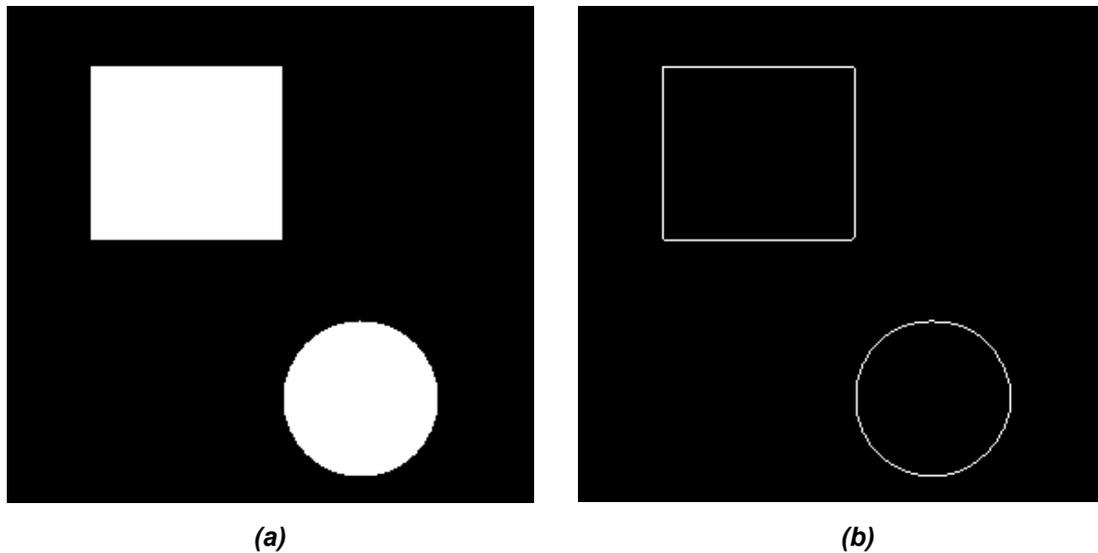


Figura 3.14. Perímetro (a) Imagen original; (b) Perímetro obtenido de los objetos de la imagen usando los operadores Sobel.

Debido a que los objetos detectados en las imágenes de mamografía no tienen formas definidas (tienen formas muy irregulares), sólo se podrán implementar los algoritmos de algunas de las cantidades anteriores. También se extraerán de las imágenes algunas propiedades estadísticas, las cuales se presentan mas adelante.

3.3.2 ESTADÍSTICA DESCRIPTIVA

La estadística descriptiva puede definirse como un conjunto de métodos que incluyen la recolección, presentación y caracterización de un conjunto de datos con el fin de describir apropiadamente las diversas características de ese conjunto [8].

Algunas cantidades usadas en la estadística son [8]:

- Media aritmética o promedio.- La media aritmética o promedio de una cantidad finita de elementos o números es igual a la suma de todos ellos dividida entre el número de elementos. Expresada de forma más intuitiva, se puede decir que la media aritmética es la cantidad total de la variable distribuida a partes iguales entre cada observación. También la media aritmética puede ser denominada como centro de gravedad de una distribución, el cual no es

necesariamente la mitad. Así, dados los números x_1, x_2, \dots, x_n , la media aritmética será igual a:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = (x_1 + x_2 + \dots + x_n) / n \quad (3.19)$$

Algunas propiedades importantes del promedio son:

- Balancea diferencias entre valores de un conjunto.
 - Puede reflejar diferencias entre valores de distintos conjuntos.
 - Puede no ser representativo cuando los valores del conjunto son extremos.
- Mediana.- La mediana de un conjunto finito de valores que se encuentra ordenado de manera ascendente o descendente, es aquel valor que divide al conjunto x_1, x_2, \dots, x_n en dos partes iguales, de forma que el número de valores mayor o igual a la mediana es igual al número de valores menores o igual a estos.

La mediana se puede obtener usando alguno de los siguientes criterios:

- Si el número de valores es impar, la mediana es el valor medio, el cual corresponde al dato $x_{\frac{n}{2}}$.
- Cuando el número de valores en el conjunto es par, no existe un solo valor medio, si no que existe dos valores medios, en tal caso, la mediana es el promedio de los valores, es decir, la mediana es numéricamente igual a:

$$med = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2} \quad (3.20)$$

Los valores extremos del conjunto no tienen efectos importantes sobre la mediana, como sí ocurre con la media aritmética.

- Desviación estándar.- Término estadístico que mide qué tan dispersos se encuentran los datos de una muestra o de una población respecto a su valor medio.

$$\sigma = \sqrt{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)} \quad (3.21)$$

Para conocer con detalle un conjunto de datos, no basta con conocer las medidas de tendencia central, sino que necesitamos conocer también la desviación que representan los datos en su distribución, con objeto de tener una visión de los mismos más acorde con la realidad a la hora de describirlos e interpretarlos para la toma de decisiones.

Una desviación estándar grande indica que los puntos están lejos de la media y una desviación pequeña indica que los datos están agrupados cerca de la media.

- Rango.- el rango se define como la diferencia entre el dato mayor y el dato menor de un conjunto de datos. Se puede calcular de la siguiente manera:

$$Rango = x_{\max} - x_{\min} \quad (3.22)$$

3.4 CONCLUSIONES

La segmentación de las imágenes de mamografía es una parte primordial para este trabajo, pues es el punto de partida para poder llevar a cabo el análisis. De las técnicas consultadas en la bibliografía para este capítulo, se encontró la segmentación morfológica combinada con técnicas de umbral permite dividir las imágenes de mamografía de manera automática.

Las partes en las que se divide la imagen pueden ser analizadas usando algunas técnicas de medición geométrica, pero también se pueden utilizar algunas cantidades estadísticas, como las que fueron presentadas en este capítulo.

3.5 REFERENCIAS

- [1] R. C. González, R. E. Woods, “Tratamiento Digital de Imágenes”, Addison Wesley/Díaz de Santos, 1996. Páginas 215-218, 447-482, 558-600.
- [2] G. Ritter. “Handbook of Computer Vision Algorithms in Image Algebra”. CRC Press. 2001. Páginas 79-88, 173-179.
- [3] <http://en.wikipedia.org/wiki/>
- [4] Matlab 7.0 Image Processing Toolbox.
- [5] Harley R. Myler, Arthur R. Weeks. “The Pocket Handbook of Image Processing Algorithms in C”. Prentice Hall. 1993.
- [6] Domingo Mery, “Extracción de Características”. Departamento de Ciencia de la Computación, Universidad Católica de Chile. 2006.
- [7] E. Gutiérrez et. al. “Utilización de momentos estadísticos y redes neuronales en la clasificación de cabezas de espermatozoides de verraco”, XXV Jornadas de Automática. Ciudad Real, España. Septiembre 2004.
- [8] Matlab 7.0 Statistics Toolbox.
- [9] Diccionario Internacional SIMON AND SCHUSTER Inglés/Español, Español/Inglés.

CAPÍTULO 4

REDES NEURONALES ARTIFICIALES

4.1 INTRODUCCIÓN

El cerebro es un procesador de información con características muy notables, es capaz de procesar a gran velocidad grandes cantidades de información procedentes de los sentidos, combinarla o compararla con la información almacenada y dar respuestas adecuadas incluso en situaciones nuevas.

Aunque todavía no se sabe mucho sobre la forma o manera en que el cerebro aprende a procesar la información, se han desarrollado modelos que tratan de imitar tales habilidades; denominados Redes Neuronales Artificiales (RNA). La elaboración de estos modelos supone en primer lugar la deducción de los rasgos o características esenciales de las neuronas biológicas y sus conexiones, y en segundo lugar, la implementación del modelo en una computadora de forma que se pueda simular.

4.2 REDES NEURONALES BIOLÓGICAS

El cerebro humano se compone de decenas de billones de neuronas interconectadas entre sí formando circuitos o redes que desarrollan funciones específicas.

Una neurona típica recoge señales procedentes de otras neuronas a través de una inmensa cantidad de delicadas estructuras llamadas dendritas. La neurona emite impulsos de actividad eléctrica a lo largo de una fibra larga y delgada, denominada axón, que se divide en millares de ramificaciones (ver Figura 4.1) [1,2]. Las extremidades de estas ramificaciones llegan hasta las dendritas de otras neuronas y establecen conexiones llamadas sinapsis, en las cuales se produce una transformación de un impulso eléctrico en un mensaje

neuroquímico mediante la liberación de sustancias llamadas neurotransmisores [2,3].

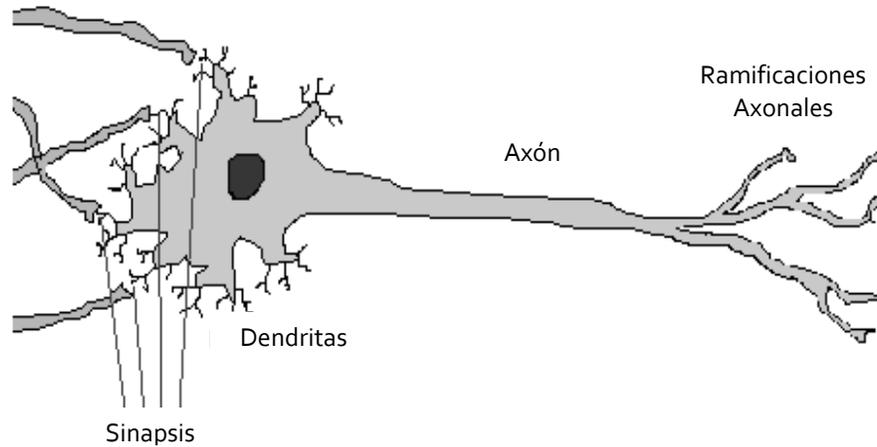


Figura 4.1. Neurona y conexiones sinápticas.

El efecto de los neurotransmisores sobre la neurona receptora puede ser excitatorio o inhibitorio, y es variable, de manera que se puede hablar de la fuerza o efectividad de una sinapsis [2]. Las señales excitatorias e inhibitorias recibidas por una neurona se combinan, y en función de la estimulación total recibida, la neurona toma un cierto nivel de activación, que se traduce en la generación de breves impulsos nerviosos con una determinada frecuencia o tasa de disparo, y su propagación a lo largo del axón hacia las neuronas con las cuales se establece comunicación. Este efecto se muestra en la Figura 4.2.

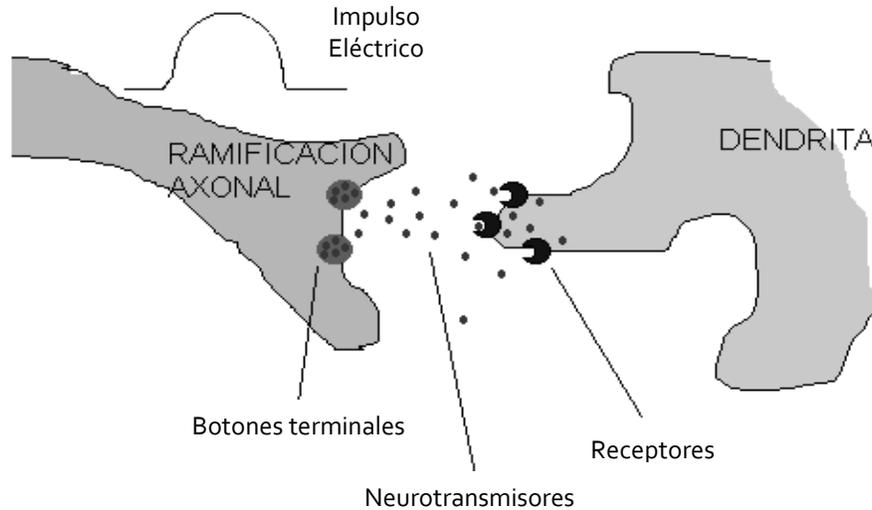


Figura 4.2. Sinapsis.

De esta manera, la información se transmite de unas neuronas a otras y va siendo procesada a través de las conexiones sinápticas y las propias neuronas. El aprendizaje de las redes neuronales se produce mediante la variación de la efectividad de las sinapsis.

4.3 REDES NEURONALES ARTIFICIALES

Conforme la ciencia y la tecnología han ido avanzando, uno de los retos más importantes que ha enfrentado el hombre es la construcción de sistemas inteligentes, entendiéndose sistema como cualquier dispositivo físico o lógico capaz de realizar una tarea requerida. Precisamente éste es el objetivo de la disciplina científica conocida como Inteligencia Artificial [4].

Dentro de la Inteligencia Artificial se pueden distinguir dos grandes áreas. Una se ocupa de la construcción de sistemas con características que se puedan definir como inteligentes. A este campo se lo denomina Inteligencia Artificial Simbólica [4]. En este caso, se define el problema a resolver y se diseña el sistema capaz de resolverlo siguiendo esquemas prefijados por la disciplina. Los Sistemas Expertos siguen este esquema: se introducen una serie de reglas lógicas que recogen el conocimiento de un experto sobre una materia, y

mediante mecanismos de inferencia parecidos a los que empleamos al razonar, se sacan conclusiones.

Frente a esta perspectiva se encuentra la otra gran área de la Inteligencia Artificial: la Sub-simbólica [4]. En este caso no se realizan diseños a alto nivel de sistemas capaces de resolver los problemas utilizando las técnicas de la disciplina, sino que se parte de sistemas genéricos que van adaptándose y construyéndose hasta formar por sí mismos un sistema capaz de resolver el problema.

Una perspectiva simbólica consiste en el estudio de los mecanismos de razonamiento humano a alto nivel: cómo nos enfrentamos a un problema, cómo lo abordamos y resolvemos; y se elaboran programas que realizan las mismas tareas. Cuanto mejor haya podido entenderse la forma de razonar humana, más eficiente será el sistema producido a la hora de resolver los problemas planteados. Es en este campo donde se encuentran las Redes de Neuronas Artificiales.

4.3.1 DEFINICIÓN

Existen numerosas formas de definir lo que son las redes neuronales, desde las definiciones cortas y genéricas hasta las que intentan explicar más detalladamente lo que significa red neuronal:

Una Red Neuronal Artificial (RNA) es un sistema masivo de procesamiento paralelo distribuido que está compuesto de unidades de proceso simples, y tiene una predisposición natural para almacenar conocimiento experimental y transformarlo para un uso determinado [5].

La RNA asemeja al cerebro en dos aspectos [5]:

- 1. La RNA adquiere el conocimiento de su entorno a través de un proceso de aprendizaje.*
- 2. La fuerza o importancia de las interconexiones entre las neuronas, conocidas como pesos sinápticos, se usan para almacenar el conocimiento adquirido.*

4.4 CARACTERÍSTICAS PRINCIPALES DE LAS REDES NEURONALES ARTIFICIALES

4.4.1 ESTRUCTURA BÁSICA

Una RNA se compone de varias unidades de proceso, cada una de las cuales se compone de un núcleo encargado de los cálculos, una red o vector de conexiones de entrada, y una salida (ver Figura 4.3) [2,4,6]:

- Conexiones ponderadas: hacen el papel de las conexiones sinápticas, el peso de la conexión equivale a la fuerza o efectividad de la sinapsis. La existencia de conexiones determina si es posible que una unidad influya sobre otra, el valor de los pesos y el signo de los mismos definen el tipo (excitatorio/inhibitorio) y la intensidad de la influencia.
- Función de red: Calcula el valor de base o entrada total a la unidad, generalmente como una simple suma ponderada de todas las entradas recibidas, es decir, de las entradas multiplicadas por el peso o valor de las conexiones. Equivale a la combinación de las señales excitatorias e inhibitorias de las neuronas biológicas.
- Función de activación: Se encarga de calcular el nivel o estado de activación de la neurona en función de la entrada total.

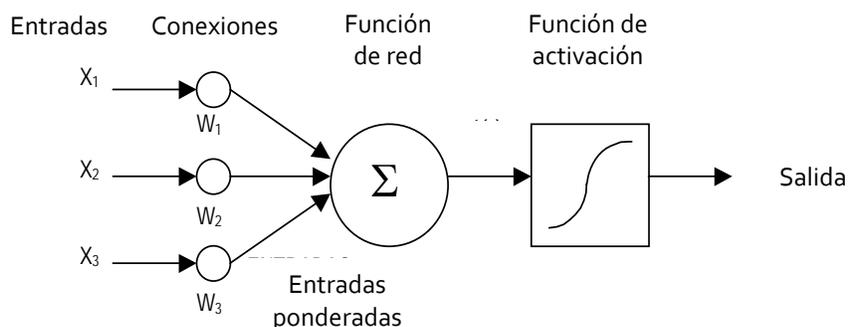


Figura 4.3. Diagrama básico de una red neuronal artificial.

- Salida: calcula la salida de la neurona en función de la activación de la misma, aunque normalmente no se aplica más que la función identidad, y se

toma como salida el valor de activación. El valor de salida cumplirá la función de la tasa de disparo en las neuronas biológicas.

4.4.2 FASES EN LA IMPLEMENTACIÓN DE UNA RED NEURONAL ARTIFICIAL

Existen dos fases en la implementación de las RNA: la fase de aprendizaje o entrenamiento, que es en la que se definen los parámetros de la red; y la fase de prueba, que es en la que se analizan el rendimiento de la red con los parámetros obtenidos anteriormente.

- En la fase de aprendizaje los parámetros de la red se obtienen a partir de datos representativos llamados *patrones de entrenamiento*. El objetivo en esta fase es lograr que la RNA entregue la salida deseada para los datos de entrada introducidos con la mayor eficiencia posible. Para lograr esto se utilizan diversos algoritmos para “diseñar” a la RNA. Existen tres tipos principales de aprendizaje [7]:
 - o Supervisado.- Los datos para el entrenamiento están constituidos por varios pares de patrones de entrenamiento de entrada-salida. El hecho de conocer la salida implica que el entrenamiento se beneficia con la supervisión de un maestro (ver Figura 4.4).
 - o No supervisado.- Los datos de entrenamiento consisten sólo en patrones de entrada. Por lo tanto, la red es entrenada sin el beneficio de un maestro. La red aprende a adaptarse basada en las experiencias recogidas anteriormente (ver Figura 4.5).
 - o Híbrido.- Es una mezcla de los dos anteriores, y tiene como propósito el optimizar el aprendizaje de la red.
- En la fase de prueba se utilizan datos diferentes a los empleados en la fase anterior. En esta fase generalmente se verifica la eficiencia de la RNA diseñada.

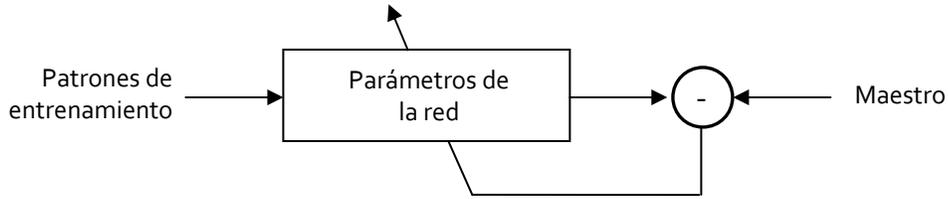


Figura 4.4. Entrenamiento supervisado.

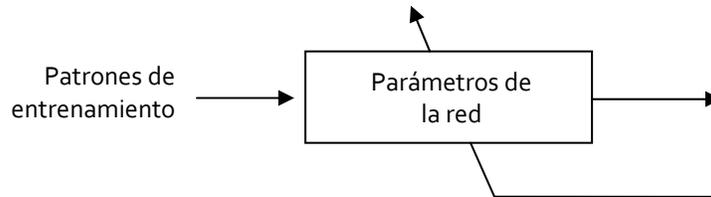


Figura 4.5. Entrenamiento no supervisado.

4.4.3 CLASIFICACIÓN DE REDES NEURONALES

Existen varios tipos de clasificación de las RNA; tipo de aprendizaje (mencionados anteriormente), mecanismos de asociación, arquitectura, etc.

En la clasificación basada en la arquitectura se tienen dos grupos principales [4,6,7]:

- Unidireccional.- También es conocida como FeedForward. La estructura de esta red consiste en capas de neuronas donde la salida de una neurona de una capa, alimenta todas las neuronas de la capa siguiente tal como se observa en la Figura 4.6.

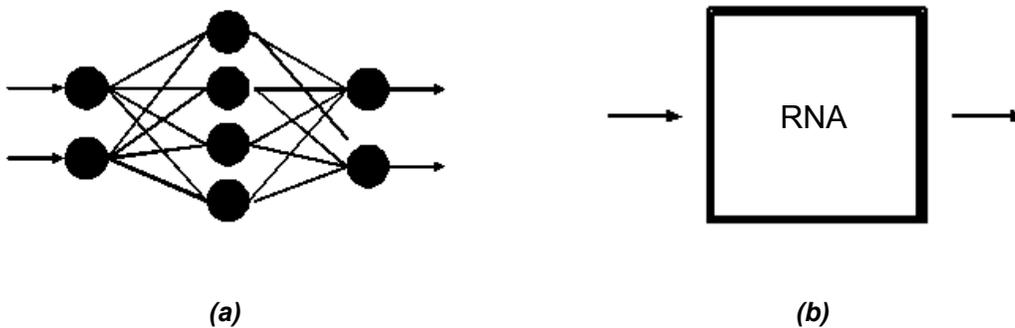


Figura 4.6. Red neuronal unidireccional (a) Diagrama esquemático, (b) Diagrama a bloques.

- Recurrente.- Es aquella que posee conexiones de realimentación, como se puede ver en la Figura 4.7, las cuales proporcionan un comportamiento dinámico.

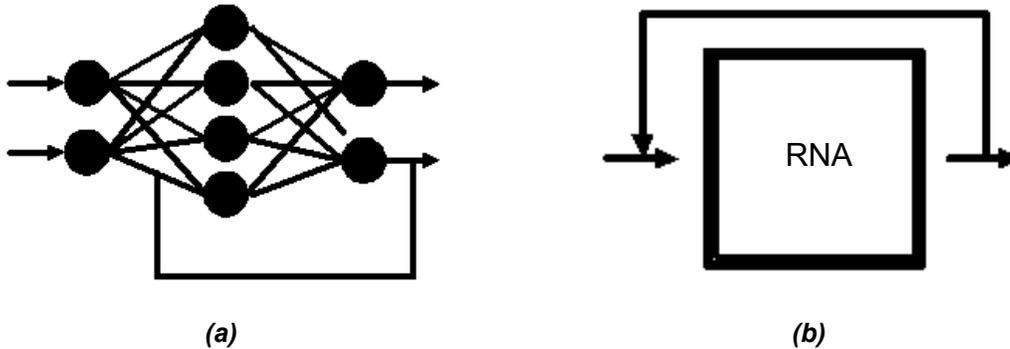


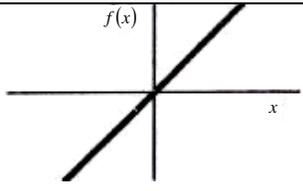
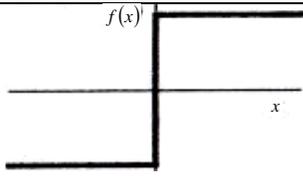
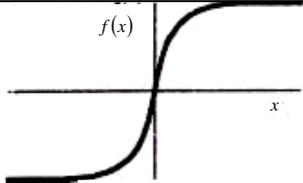
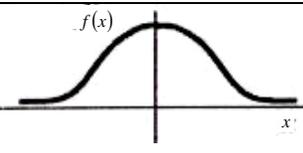
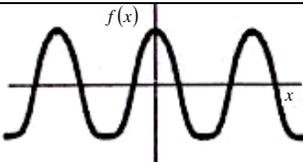
Figura 4.7. Red neuronal recurrente (a) Diagrama esquemático, (b) Diagrama a bloques.

En general los siguientes parámetros son importantes para definir la arquitectura de una red neuronal: número de capas, número de neuronas en cada capa y tipo de conexión entre dos neuronas, que definen si la red es unidireccional o recurrente.

4.4.4 FUNCIONES DE ACTIVACIÓN

El valor que se va obteniendo en cada una de las unidades de proceso que constituyen a la RNA se filtra a través de una función conocida como función de activación, y es la que nos da la salida de cada neurona o de la red completa. Según para lo que se desee entrenar la RNA, se suele escoger una función de activación u otra en ciertas neuronas de la red [4,6]. La Tabla 4.1 muestra diferentes funciones de activación usadas en las RNA.

Tabla 4.1. Funciones de activación.

Nombre	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón o limitador duro	$y = \text{sign}(x)$ $y = \text{hardlim}(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Sigmoidal	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(ax + \varphi)$	$[-1, +1]$	

4.4.5 ALGUNOS MODELOS DE REDES NEURONALES IMPORTANTES

Warren McCulloch y Walter Pitts realizaron el primer modelo matemático de una RNA [4]. El modelo de McCulloch-Pitts está basado en la idea de que las neuronas operan mediante impulsos binarios. Este modelo introduce la idea de una función de paso por umbral utilizada posteriormente por muchos modelos de las RNA. Algunos modelos de redes neuronales artificiales se muestran en la Tabla 4.2:

Tabla 4.2. Principales Redes Neuronales Artificiales.

Nombre de la red	Año de aparición	Inventada/desarrollada por
Perceptron	1957	Frank Rosenblatt
Adaline/Madaline	1960	Bernard Widrow
Avalancha	1967	Stephen Grossberg
Neocognitron	1978-84	Kunihiko Fukushima
Mapas de Auto Organización (SOM)	1980-84	Teuvo Kohonen
Hopfield	1982	John Hopfield
Máquina de Boltzmann	1984	Terrence Sejnowski, Geoff Hinton
Memoria Asociativa Bidireccional	1985	Bart Kosko
Teoría Resonancia Adaptiva (ART)	1986	Gail Carpenter, Stephen Grossberg
Función de Base Radial (RBF)	1988	D. S. Broomhead, D. Lowe
Máquinas de Soporte Vectorial (SVM)	1992	Vapnik, Boser, Guyon

4.5 CONCLUSIONES

En este capítulo se dio una breve introducción al tema de las Redes Neuronales Artificiales (RNA): cómo se clasifican, cómo es su funcionamiento básico, cuáles son los pasos esenciales para implementar una RNA, etc. También se hizo una comparación entre éstas y las redes neuronales biológicas, para así entender de una manera más sencilla cómo es que las RNA funcionan.

4.6 REFERENCIAS

- [1] Nikola K. Kazabov, “Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering”. The MIT Press. 1998. Páginas 251-259.
- [2] Mario Gómez Martínez, “Teoría y simulación de redes neuronales artificiales”. Universidad Politécnica de Valencia. 1999.
- [3] <http://ohm.edu.co/neuronales/main1.htm>

- [4] Pedro Isasi Viñuela, Inés M. Galván León, “Redes Neuronales Artificiales, un enfoque práctico” Pearson-Prentice Hall, 2004. Páginas 1-14.
- [5] S. Haykin, “Neural Networks, a comprehensive foundation”, 2nd Edition, Prentice Hall. 1999. Páginas 256-293.
- [6] José Hilera González, Víctor Martínez Hernando, “Redes Neuronales Artificiales, Fundamentos, modelos y aplicaciones”. Alfa Omega. 2000. Páginas 1-95.
- [7] Cristina Juárez Landín, “Almacenamiento de señales de EEG y reconstrucción de sus características usando redes neuronales”. Tesis de Maestría. SEPI-ESIME-Culhuacán. Junio del 2003. Páginas 47-59.

CAPÍTULO 5

LA FUNCIÓN DE BASE RADIAL Y LA ESTADÍSTICA DE ORDEN

5.1 INTRODUCCIÓN

Existen gran variedad de Redes Neuronales Artificiales, algunas de las cuales se mencionan en la sección 4.4.5, y cada una de las cuales tiene características distintas que se pueden consultar en la literatura. En este capítulo se presenta la Función de Base Radial (RBF, por sus siglas en inglés) para implementar el clasificador propuesto, en combinación con la estadística robusta. Algunos de los criterios usados para escoger la red propuesta fueron:

- Que fuera una red de fácil implementación.
- Que no hubiera trabajos reportados sobre su uso en el área de clasificación de imágenes médicas [1,2,3,4].
- Que se pudiera manipular para implementar mejoras usando Estadística Robusta.

5.2 FUNCIÓN DE BASE RADIAL (RBF)

Las Redes de Neuronas de Base Radial son redes multicapa con conexiones hacia delante, y se caracterizan por estar formadas por una única capa oculta, y cada neurona de esta etapa posee un carácter local, en sentido de que cada neurona de la red se activa en una región diferente del espacio de patrones de entrada [5,6]. Este carácter local viene dado por el uso de las llamadas funciones de base radial como funciones de activación.

En 1988, Broomhead y Lowe introducen la Función de Base Radial (RBF) como un método para hacer ajuste a funciones no lineales (clasificación no lineal), aunque la mayor contribución a la teoría, diseño y aplicaciones de este tipo de

redes la hicieron Moody y Marken (1989), Renals (1989), y Poggio y Gorossi (1990) [5].

Uno de los objetivos iniciales de los desarrolladores de esta red era construir una red de neuronas que requiriese menos tiempo que el Perceptrón multicapa y de ese modo disponer de una red de neuronas que pudiera ser apropiada para aplicaciones en tiempo real. Esto se consiguió incorporando funciones de activaciones locales en las neuronas ocultas de la red, lo cual permitía que sólo unas pocas neuronas ocultas tuvieran que ser procesadas para nuevos patrones de entrada [5].

5.2.1 CARACTERÍSTICAS DE LA RBF

Las principales características de esta red neuronal son [5,6,7]:

- Usa un número mínimo de nodos en comparación con otras redes, reduciendo el número de cálculos para el aprendizaje.
- La arquitectura es simple (Solo 3 capas).
- Tienen amplia eficiencia en la fase de entrenamiento.
- Mejor desempeño con un mayor número de datos de entrenamiento.
- Varios algoritmos pueden ser empleados para encontrar los parámetros más apropiados para la RBF.
- Buen clasificador.

5.2.2 ARQUITECTURA DE UNA RBF

Una RBF está conformada de tres capas [5,6,7]. La Figura 5.1 muestra la arquitectura de la red RBF. De manera general, las características de cada una de ellas son las siguientes:

1. La primer capa (capa de entrada) se encarga de leer los datos que se van a introducir a la RBF.
2. La segunda capa (capa oculta) está completamente interconectada entre todos sus nodos con las capas de entrada y de salida y se activa a través de una función radial, y,

3. La tercer y última capa (capa de salida), se interconecta a la capa oculta y es activada a través de una función lineal continua.

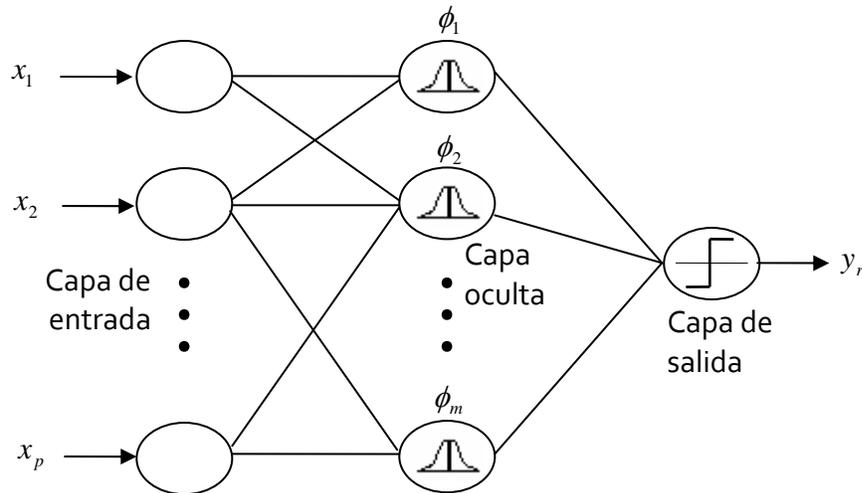


Figura 5.1. Capas de una RBF.

5.2.3 FUNCIONAMIENTO DE UNA RBF

Dada una red de neuronas de base radial con p neuronas en la capa de entrada, m neuronas en la capa oculta y r neuronas en la capa de salida, las activaciones de las neuronas de salida para el patrón de entrada n , $X(n) = (x_1(n), x_2(n), \dots, x_p(n))$, denotadas como $y_k(n)$, vienen dadas por la siguiente expresión [3]:

$$y_k(n) = \sum_{i=1}^m \omega_{ik} \phi_i(n) + u_k \quad \text{para } k = 1, 2, \dots, r \quad (5.1)$$

donde ω_{ik} representa el peso de la conexión de la neurona oculta i a la neurona de salida k , u_k es el umbral de la neurona de salida k y $\phi_i(n)$ son las activaciones de las neuronas ocultas para el patrón de entrada $X(n)$.

Las funciones ϕ_i determinan las activaciones de las neuronas ocultas de la red en función del vector de entrada a la red $X(n)$ y vienen dadas por la siguiente expresión [5]:

$$\phi_i(n) = \phi\left(\frac{\|X(n) - C_i\|}{d_i}\right) \text{ para } i = 1, 2, \dots, m \quad (5.2)$$

donde ϕ es una función de base radial; $C_i = (c_{i1}, \dots, c_{ip})$ son vectores que representan los centros de la función de base radial; d_i son los números reales que representan la desviación, anchura o dilatación de la función de base radial; y $\|\cdot\|$ es la distancia euclídea del vector de entrada $X(n)$ al centro C_i , definida como [5]:

$$\|X(n) - C_i\| = \left(\sum_{j=1}^p (x_j(n) - c_{ij})^2 \right)^{\frac{1}{2}} \quad (5.3)$$

Por lo tanto, la activación de una neurona oculta en las redes de base radial depende de la distancia del patrón de entrada $X(n)$ al centro C_i de la función de base radial. Estas funciones base ϕ poseen un carácter local, pues son funciones que alcanzan un nivel cercano al máximo de su recorrido cuando el patrón de entrada está próximo al centro de la neurona; a medida que el patrón se aleja del centro, el valor de la función va tendiendo al máximo de su recorrido (ver Figura 5.2).

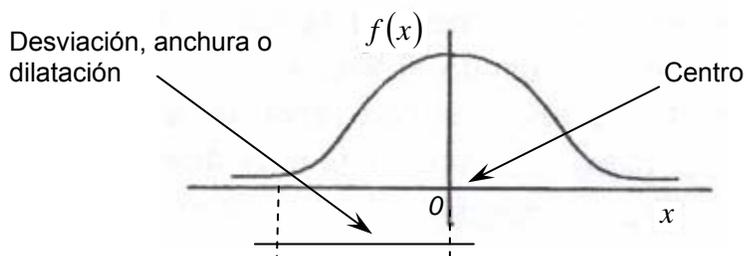


Figura 5.2. Elementos principales de una Función de Base Radial.

La función radial ϕ puede adoptar diferentes formas como las que se presentan en la Figura 5.3. Las expresiones para estas funciones se muestran a continuación [5]:

- Función gaussiana:

$$\phi(r) = \exp\left(\frac{-r^2}{2}\right) \quad (5.4)$$

- Función inversa cuadrática:

$$\phi(r) = \frac{1}{1+r^2} \quad (5.5)$$

- Función multicuadrática inversa:

$$\phi(r) = \frac{1}{\sqrt{1+r^2}} \quad (5.6)$$

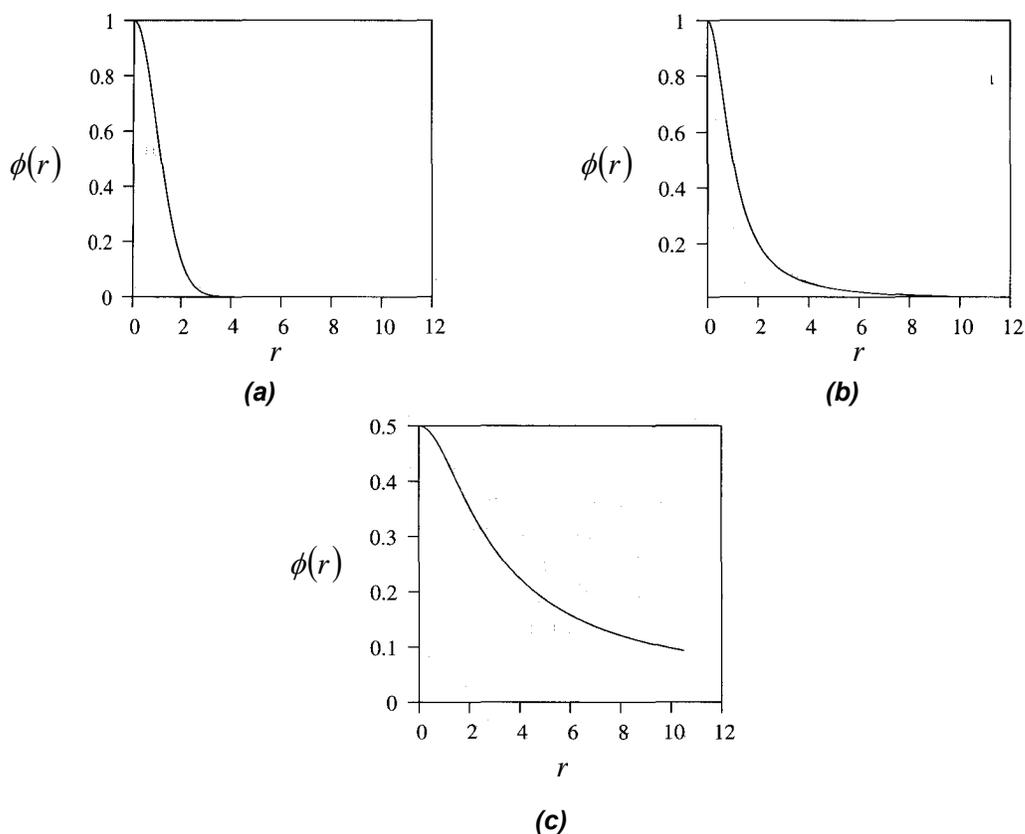


Figura 5.3. Funciones de base radial. a) Función Gaussiana, b) Función cuadrática inversa, c) Función multicuadrática inversa.

En el contexto de las redes de neuronas de base radial, la más utilizada es la función gaussiana. Por tanto, la activación de las neuronas ocultas de las redes de base radial viene dada, generalmente, por la siguiente expresión [5]:

$$\phi_i(n) = \exp\left(-\frac{\|X(n) - C_i\|^2}{2d_i^2}\right) = \exp\left(-\frac{\sum_{j=1}^N (x_j(n) - C_{ij})^2}{2d_i^2}\right) \quad (5.7)$$

para $i = 1, 2, \dots, m$

Las salidas de las redes de neuronas de base radial (5.7) son, por tanto, una combinación lineal de funciones radiales, cada una de las cuales se activa para una determinada porción del espacio definido por los patrones de entrada.

5.2.4 ENTRENAMIENTO DE UNA RBF

El entrenamiento de esta red es solamente hacia adelante. De este modo, la salida de una red RBF, en general, está influenciada por una transformación no lineal originada en la capa oculta a través de la función radial y una lineal en la capa de salida a través de la función lineal continua.

El entrenamiento que maneja esta red neuronal es híbrido, pues combina un aprendizaje no supervisado (determinación de los parámetros de las funciones radiales) y supervisado (determinación de los pesos) [5].

5.2.4.1 APRENDIZAJE NO SUPERVISADO

Para determinar los centros de cada función radial, se empleó el algoritmo de agrupamiento de las k -medias², que es un método de agrupamiento que se basa en la partición de un grupo de datos dado en subgrupos, cada uno de los cuales debe ser tan homogéneo como sea posible [5,6,8]. Al usar este algoritmo se pueden obtener los centros de cada función radial en el espacio de datos de entrada en donde existen datos relevantes.

Una vez determinados los centros de las funciones de base radial, las amplitudes o desviaciones de dichas funciones deben de calcularse de manera que cada neurona oculta se active en una región del espacio de entrada.

² Para mayor referencia, ver el anexo A "Algoritmo de las K-medias".

Para obtener las amplitudes de las funciones radiales en un entorno de programación, se puede hacer de forma manual para lograr una sensibilidad deseada. Esto propiamente entra dentro de la etapa de aprendizaje supervisado, que se describe más adelante.

5.2.4.2 APRENDIZAJE SUPERVISADO

En esta fase se calculan los pesos y umbrales de las neuronas de salida de la red, aunque como se dijo anteriormente, según la referencia [9] la anchura de una función radial, al poder ser manipulada, podría entrar dentro de esta etapa del entrenamiento.

Una manera de poder manipular la amplitud de cada una de las funciones radiales es mediante el uso de un factor de ponderación que permita ajustar la sensibilidad de una función radial. El esquema de este ajuste se muestra en la Figura 5.4.

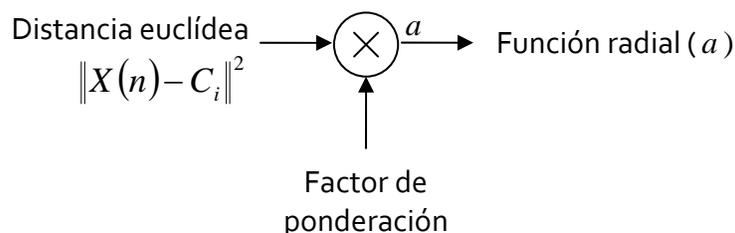


Figura 5.4. Ajuste de amplitud.

El cálculo de los pesos y umbrales de la red neuronal sirve para ajustar la salida de la red a un valor deseado. En la literatura se puede encontrar que los métodos más utilizados para el ajuste de pesos y umbrales son la matriz seudoinversa y mínimos cuadrados, que se pueden consultar en las referencias [5] y [6].

Para la RBF implementada no se usó ninguno de los métodos anteriores, ya que los datos que se pretenden ajustar tienen una variación considerable, por lo que se optó por usar una función de transferencia de saturador lineal duro para cada función radial [10].

$$\text{hardlim}(x) = \begin{cases} 1, & x \geq 0 \\ -1, & \text{en cualquier otro caso} \end{cases} \quad (5.8)$$

Cabe mencionar que el umbral se determinó en base a las simulaciones realizadas.

5.3 ESTADÍSTICA ROBUSTA

Muchos de los métodos de la estadística clásica se basan en suposiciones que en ocasiones no concuerdan con la realidad. De manera particular, con frecuencia se asume que los datos de una muestra tienen una distribución normal, o al menos aproximada, o que el teorema del límite central³ se puede aplicar para estimar una distribución normal. Desafortunadamente, cuando no existen colas (outliers) en la muestra de datos, los métodos clásicos son poco útiles. La estadística robusta busca métodos que emulan a los clásicos, pero en los que los datos que se encuentran muy alejados de la media no afectan indebidamente a las suposiciones de los modelos.

No existe una definición formal de lo que es la estadística robusta, más sin embargo se puede partir de la idea de qué es [11]:

En un sentido informal, la estadística robusta de un conjunto de conocimientos, que bien podrían llamarse “teorías de robustez”, relacionados con desviaciones a las suposiciones ideales hechas en la estadística clásica.

Los principales objetivos de la estadística robusta son los siguientes [11]:

1. Describir la estructura a la que se ajusta mejor el conjunto de datos.
2. Identificar puntos o subestructuras de la muestra de datos que presenten una desviación considerable para analizarlos posteriormente, si es que así se desea.

³ Este teorema indica que, bajo condiciones muy generales, la distribución de la suma de variables aleatorias tiende a una distribución gaussiana cuando la cantidad de variables es muy grande.

5.3.1 CUANTIFICACIÓN DE ROBUSTEZ

Para cuantificar la robustez de un método existen algunas medidas, entre las que se encuentran el *punto de ruptura* y la *función de influencia* [12].

5.3.1.1 PUNTO DE RUPTURA

El punto de ruptura de un estimador es en donde la porción de observaciones incorrectas llevan a un estimador más allá de sus límites. Por ejemplo, dada una muestra de tamaño n [12],

$$\overline{X}_n = X_1 + \dots + X_n \quad (5.9)$$

Considere que algunas muestras de \overline{X}_n están contaminadas o son incorrectas para estimar la observación total. Tales muestras son consideradas que están localizadas muy lejos (outliers) de la estimación apropiada y que de alguna manera deben ser eliminadas o sustituidas por otro valor para proporcionar un resultado correcto. Dichas muestras presentan el punto de ruptura del estimador y es hasta donde el estimador funcionará correctamente.

5.3.1.2 FUNCIÓN DE INFLUENCIA

La función de influencia nos da una idea de cómo se comporta un estimador cuando se cambia un punto en la muestra de datos [11,12].

Dos de las principales funciones de influencia usadas son [13]:

- Corte Simple (Simple Cut),

$$\psi_{\text{cut}(r)}(X) = X \cdot 1_{[-r,r]}(X) = \begin{cases} X, & |X| \leq r \\ 0, & \text{en otro caso} \end{cases} \quad (5.10)$$

- Tukey (Tukey biweight),

$$\psi_{\text{bi}(r)}(X) = \begin{cases} X^2(r^2 - X^2), & |X| \leq r \\ 0, & \text{en otro caso} \end{cases} \quad (5.11)$$

donde X es la muestra de datos y r es una constante real. El parámetro r depende de los datos que se vayan a procesar y puede cambiarse para diferentes funciones de influencia.

5.3.2 ESTIMADORES M

Muchas aproximaciones para estimadores robustos han sido propuestas a lo largo de los años, incluyendo los estimadores R y los estimadores L . Sin embargo, los estimadores M son los más populares debido a su generalidad, alto punto de ruptura y a su eficiencia [12]. Los estimadores M son una generalización de los estimadores de máxima verosimilitud (MLEs, por sus siglas en inglés), y fueron propuestos por Huber en 1964.

5.3.3 ESTIMADOR DE RANGO TIPO M (RM)

El estimador que se muestra en la ecuación (5.12) surge de la combinación entre los estimadores R y M [13]. Este estimador es conocido como el estimador de Mediana Tipo M (estimador MM). El estimador MM no iterativo está dado por [13],

$$\mu_k = med\{\mathbf{X}\varphi(\mathbf{X} - \theta)\} \quad (5.12)$$

donde \mathbf{X} es la muestra de datos de entrada, φ es la función de influencia normalizada $\psi: \psi(\mathbf{X}) = \mathbf{X}\varphi(\mathbf{X})$, $\theta = med\{X_k\}$ es la estimación inicial, y $k=1, 2, \dots, N_k$. El estimador R tiene buenas propiedades para la discriminación de datos cuyo valor tiene una gran diferencia con respecto de la media de una muestra de datos y el estimador M usa diferentes funciones de influencia de acuerdo al esquema de Huber proporcionando mayor robustez. Al hacer esta combinación en el estimador RM se espera que el rendimiento sea mejor en comparación al de los estimadores R y M por sí solos [13].

5.4 CONCLUSIONES

La Función de Base Radial es un buen clasificador que se puede implementar de manera sencilla, y en los trabajos consultados en la bibliografía relacionada al análisis automático de imágenes de mamografía no se reporta su uso o implementación.

Además, dado que la base de la RBF son funciones radiales, como las mostradas en las Figuras 5.2 y 5.3, se puede hacer uso de la estadística robusta para eliminar las colas de dichas funciones, y así tratar de mejorar el rendimiento del clasificador.

5.5 REFERENCIAS

- [1] Predrag R. Bakie y Dragana P. Brzakovic, "Application of Neural Networks in Computer Aided Diagnosis of Breast Cancer". IEEE Transactions on Medical Imaging. 2002.
- [2] J. S. Suri, R. M. Rangayyan, "Recent Advances in Breast Imaging, Mammography, and Computer-Aided Diagnosis of Breast Cancer", SPIE Press, Bellingham, 2006.
- [3] Paul Sajda, "Learning Contextual Relationships in Mammograms using a Hierarchical Pyramid Neural Network". IEEE Transactions on Medical Imaging. 2002.
- [4] Samuel Oporto, Rolando Hernández, Hugo Terashima, "Detección de Microcalcificaciones en Imágenes de Mamografías Usando Diferencia de Filtros Gaussianos Optimizados". XXX Conferencia Latinoamericana de Informática CLEI 2004.
- [5] Pedro Isasi Viñuela, Inés M. Galván León, "Redes Neuronales Artificiales, un enfoque práctico" Pearson-Prentice Hall, 2004. Páginas 75-99.
- [6] S. Haykin, "Neural Networks, a comprehensive foundation", 2nd Edition, Prentice Hall. 1999. Páginas 256-293.
- [7] M. T. Musavi, W. Ahmed, K. H. Chan, K. B. Faris, D. M. Hummels. "On the Training of Radial Basis Function Classifiers" IEEE Transactions on Neural Networks. 1992.
- [8] http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial_html/kmeans.html
- [9] Matlab 7.0 Neural Network Toolbox.
- [10] Mario Gómez Martínez, "Teoría y simulación de redes neuronales artificiales". Universidad Politécnica de Valencia. 1999.

- [11] Frank R. Hampel, Elvezio M. Ronchetti, Peter J. Pousseeuw, Werner A. Stahel. "Robust Statistics, The approach based on influence functions". Wiley Series in probability and mathematical statistics. 1986. Páginas 18-70.
- [12] P. J. Huber, "Robust Statistics". Wiley. 1981. Páginas 5-65.
- [13] F. J. Gallegos-Funes, V. I. Ponomaryov, "Real-time image filtering scheme based on robust estimators in presence of impulsive noise," Real Time Imag., 10(2), 69-80 (2004).

CAPÍTULO 6

REGIONES DE INTERÉS Y CLASIFICACIÓN DE IMÁGENES DE MAMOGRAFÍA

6.1 INTRODUCCIÓN

En este capítulo se presentan las regiones de interés en imágenes de mamografía. Su clasificación, sin tomar en cuenta la forma del seno, va desde pequeños puntos que pueden ser microcalcificaciones hasta anomalías, sean o no cancerígenas, que presentan cualquier forma.

6.2 REGIONES DE INTERÉS

Mediante el uso de técnicas de segmentación como las vistas en el Capítulo 3 se puede dividir una imagen en partes o regiones de interés, que están definidas por condiciones determinadas de luminosidad u otras propiedades o características.

En el caso de este trabajo para cada mamografía se tienen 2 regiones de interés:

- Región 1, que se conforma del seno o mama, y
- Región 2 que se conforma de algún(os) objeto(s), que se pueden entender como anomalías de varios tipos.

La segmentación de la segunda región de interés no es sencilla dadas las diversas formas que en la mamografía se pueden presentar. Es por esta razón que la segmentación que se escogió para trabajar fue la que utiliza técnicas morfológicas, principalmente, pero para mejorar los resultados obtenidos se usó también el criterio de selección de umbral [1]. Esta combinación permite una buena delimitación automática de las regiones de interés, sin la necesidad de que el programa sea manipulado por un usuario. La etapa de segmentación completa se muestra en la Figura 6.1.

El software utilizado para realizar estas pruebas fue Matlab 7.0, ya que tiene incorporadas funciones de procesamiento digital de imágenes que permiten que la labor de programación sea más sencilla [2].

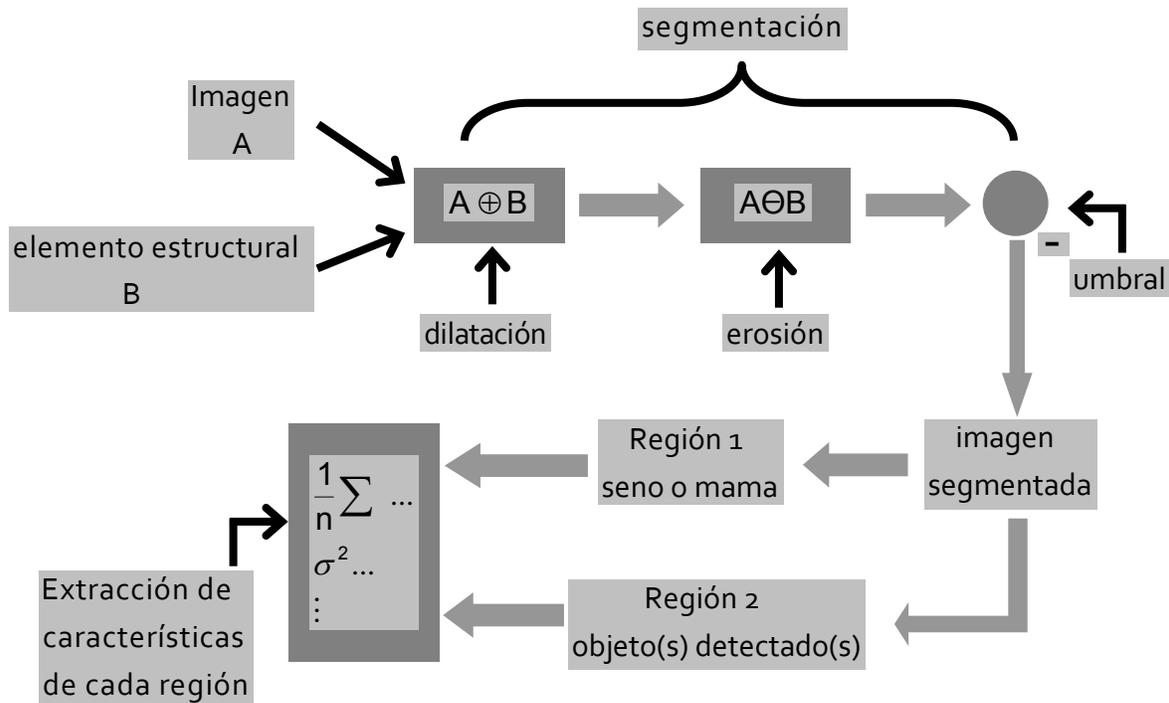


Figura 6.1. Diagrama representativo de las etapas de segmentación y extracción de características.

Para poder segmentar con técnicas morfológicas, el primer paso es la selección del elemento estructural que se va a utilizar. Se hicieron varias pruebas con elementos estructurales de tipo línea, circular y diamante, y éste último (ver Figura 6.2) fue el que presentó mejores resultados experimentales tanto en el objeto detectado como la mama.

El criterio que se usó para tomar esta decisión fue en base a los resultados visuales obtenidos.

0	1	0
1	1	0
0	1	0

Figura 6.2. Elemento estructural usado para delimitar regiones de interés.

Para lograr delimitar las regiones de interés de este trabajo, aparte de usar operaciones de morfología se tuvo que aplicar el criterio de umbral, descrito en el Capítulo 3, y así delimitar visualmente de una mejor manera las partes relevantes.

Para mostrar lo realizado en la etapa de segmentación se utilizaron 3 imágenes, obtenidas de las referencias [3] y [4], las cuales se pueden apreciar en la Figura 6.3. Estas imágenes se escogieron porque muestran tres tipos diferentes de padecimiento. Además, al ser imágenes pequeñas (de baja resolución) se puede apreciar mejor la delimitación de los objetos detectados que en imágenes de alta resolución. De esta manera se puede suponer que si el método trabaja bien para imágenes de baja resolución, también lo hará en imágenes en las que la resolución sea mayor.

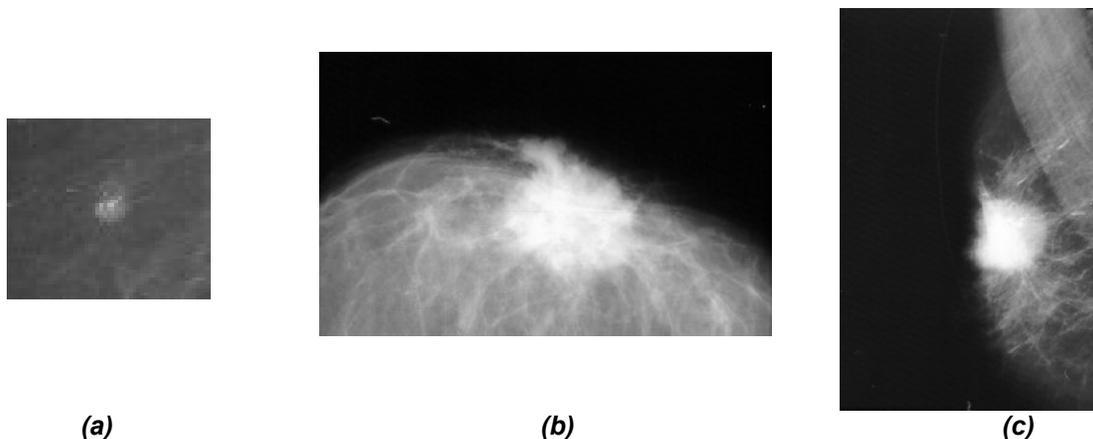


Figura 6.3. Mamografías de prueba para la etapa de segmentación.

Las imágenes de la Figura 6.3 tienen las siguientes características:

- Figura 6.3(a):

Dimensiones (píxeles)	Formato	Padecimiento
55x49	jpg 8 bits	Microcalcificación
- Figura 6.3(b):

Dimensiones (píxeles)	Formato	Padecimiento
300x190	jpg 8 bits	Masa retroareolar cancerígena
- Figura 6.3(c):

Dimensiones (píxeles)	Formato	Padecimiento
198x300	jpg 8 bits	Cáncer de mama avanzado

El primer objetivo fue lograr la segmentación del objeto extraño. En la Figura 6.4 se muestran los objetos detectados mediante el uso de técnicas de segmentación morfológica para cada una de las imágenes de prueba. Al tener la región de interés, se puede delimitar ésta en la imagen de mamografía original.

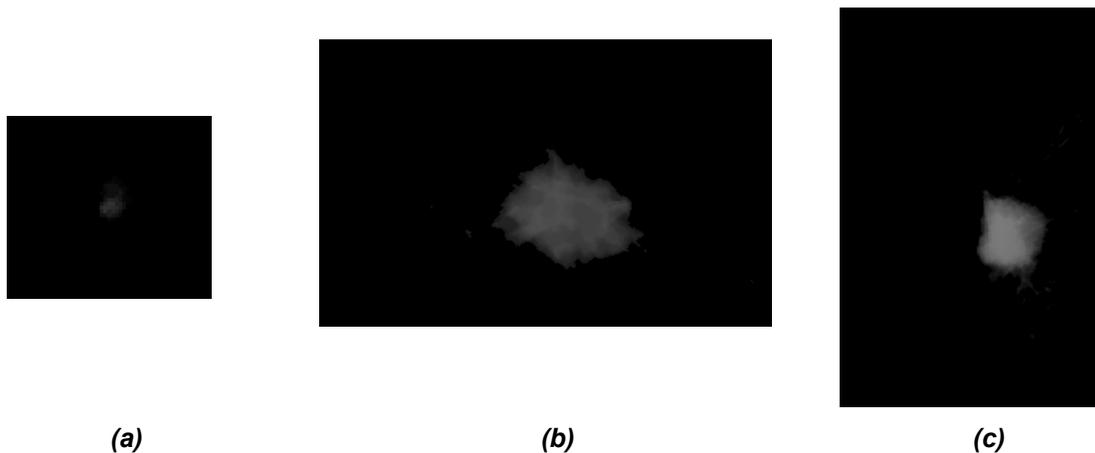


Figura 6.4. Objeto detectado en las imágenes de la Figura 6.3 mediante técnicas de segmentación morfológicas.

En la Tabla 6.1 se presenta el valor máximo de píxel de cada uno de las imágenes de la Figura 6.4. Posteriormente usando este valor se calculó el umbral para delimitar el objeto detectado.

Tabla 6.1. Valores máximos de píxeles de las imágenes de la Figura 6.4.

Objeto detectado	Valor máximo
Imagen Figura 6.4(a)	50
Imagen Figura 6.4(b)	80
Imagen Figura 6.4(c)	123

Los valores de umbral que se escogieron fueron el 10%, 15%, 20%, 25%, 30% y 35% del valor máximo del objeto detectado. Se escogieron estos valores porque no son muy altos, pues arriba del 40% ya se está discriminando gran parte del objeto detectado.

Los resultados de las Figuras 6.5 a 6.7 muestran la segmentación de las tres imágenes usando los umbrales mencionados. Se puede apreciar que cuando se va aumentando el umbral, el objeto que se detecta es más pequeño. Esto se corrobora al ver los valores de densidad de objeto que se muestran en la Tabla 6.2.

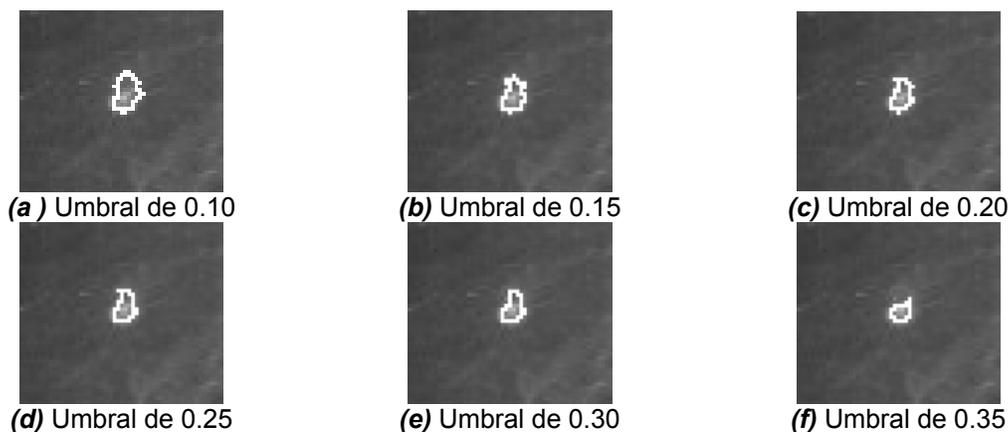


Figura 6.5. Resultados visuales de segmentación de la Figura 6.3(a).

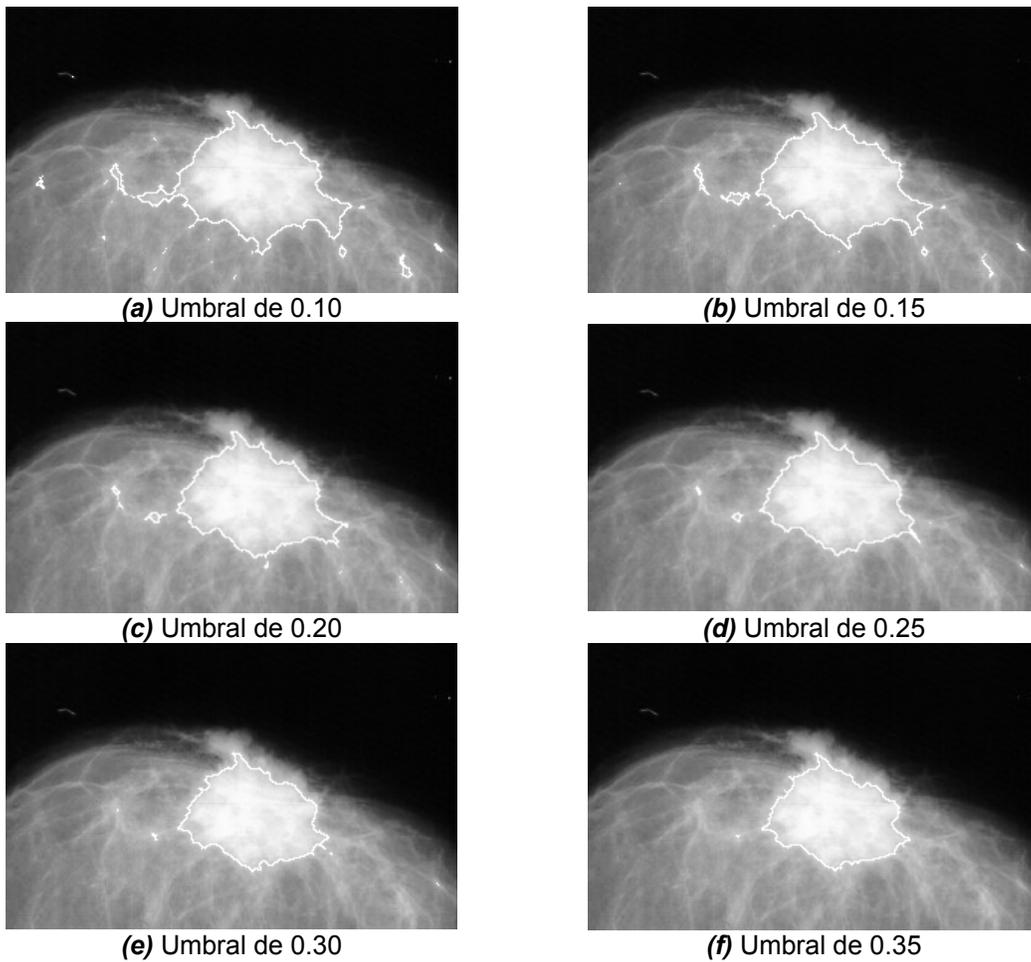


Figura 6.6. Resultados visuales de segmentación de la mamografía de la Figura 6.3(b).

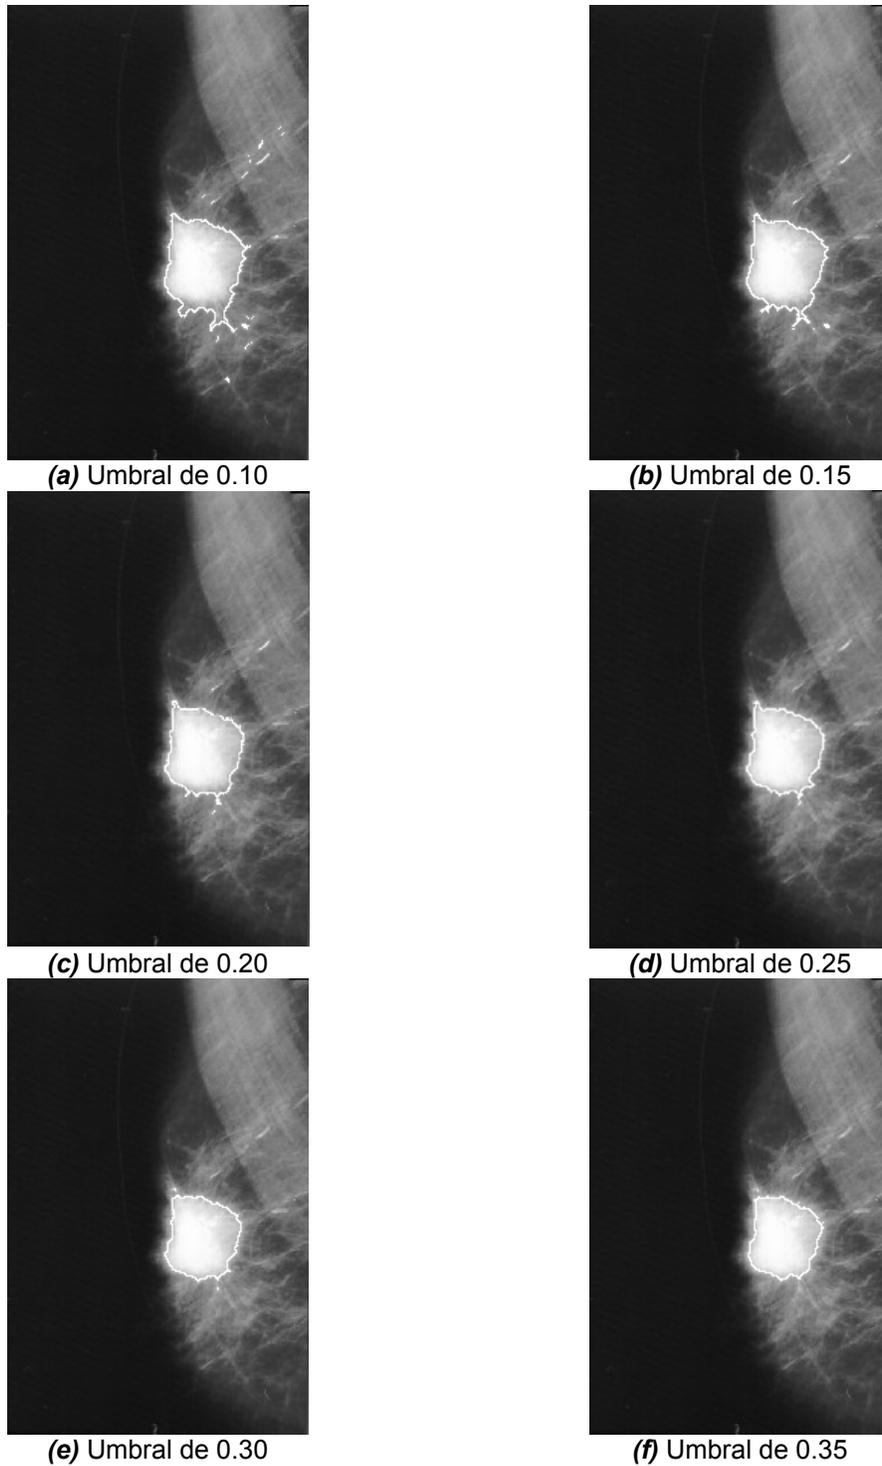


Figura 6.7. Resultados visuales de segmentación de la mamografía de la Figura 6.3(c).

El valor del umbral es calculado de acuerdo a los valores de cada mamografía, y éste debe de ser tal que no haga muy pequeño al objeto detectado, pues esto

puede provocar que la información útil se reduzca, aparte de que al trabajar con información de rango muy pequeño se delimitarían los datos que posteriormente indicarán características de la región de interés. El umbral tampoco debe ser muy pequeño, ya que con esto se puede tener mayor cantidad de información, lo que puede derivar en que se estén tomando en cuenta datos no relevantes.

Tabla 6.2. Resultados de segmentación de las mamografías de la Figura 6.3.

Mamografía	Valor de umbral	Promedio	Mediana	Rango	Área	Perímetro	Densidad de objeto
Figura 6.3(a)	0.10	118.91	115	99	70	39	21.73
	0.15	124.22	120.50	90	54	34	21.41
	0.20	126.20	122	90	49	31	19.61
	0.25	126.68	123	90	47	29	17.89
	0.30	127.89	126	87	45	28	17.42
	0.35	148.8	139	54	30	21	14.7
Figura 6.3(b)	0.10	218.97	224	85	6193	826	110.17
	0.15	222.36	228	78	5633	682	82.57
	0.20	224.90	230	84	5232	555	58.87
	0.25	227.43	232	81	4862	471	45.63
	0.30	229.63	233	65	4536	437	42.10
	0.35	231.10	234	57	4311	405	38.05
Figura 6.3(c)	0.10	212.04	217	119	2741	410	61.33
	0.15	216.44	222	117	2552	338	44.77
	0.20	220.04	225	115	2403	280	32.63
	0.25	223.09	228	104	2265	257	30.46
	0.30	225.43	230	92	2166	243	228
	0.35	227.98	233	85	2048	228	25.38

Considerando lo antes mencionado, y en base a las simulaciones realizadas con las tres mamografías mostradas, se escogió tomar un valor de umbral del 20% del valor máximo del objeto detectado, pues se observa que de esta manera se delimita bien el objeto extraño, sea muy pequeño o sea grande, sin perder grandes detalles del mismo, ni tampoco se agrega información correspondiente al seno, que es otra región de interés.

El seno es más fácil de delimitar, pues presenta formas y valores más constantes que en el caso del objeto detectado. Por eso que en base a los resultados visuales obtenidos en simulaciones hechas en las mamografías ya

mostradas, se escogió un valor de píxel de 50 como umbral para su segmentación.

Los resultados de la delimitación de las dos regiones de interés de este trabajo se muestran para 3 imágenes en las Figuras 6.8, 6.9 y 6.10.

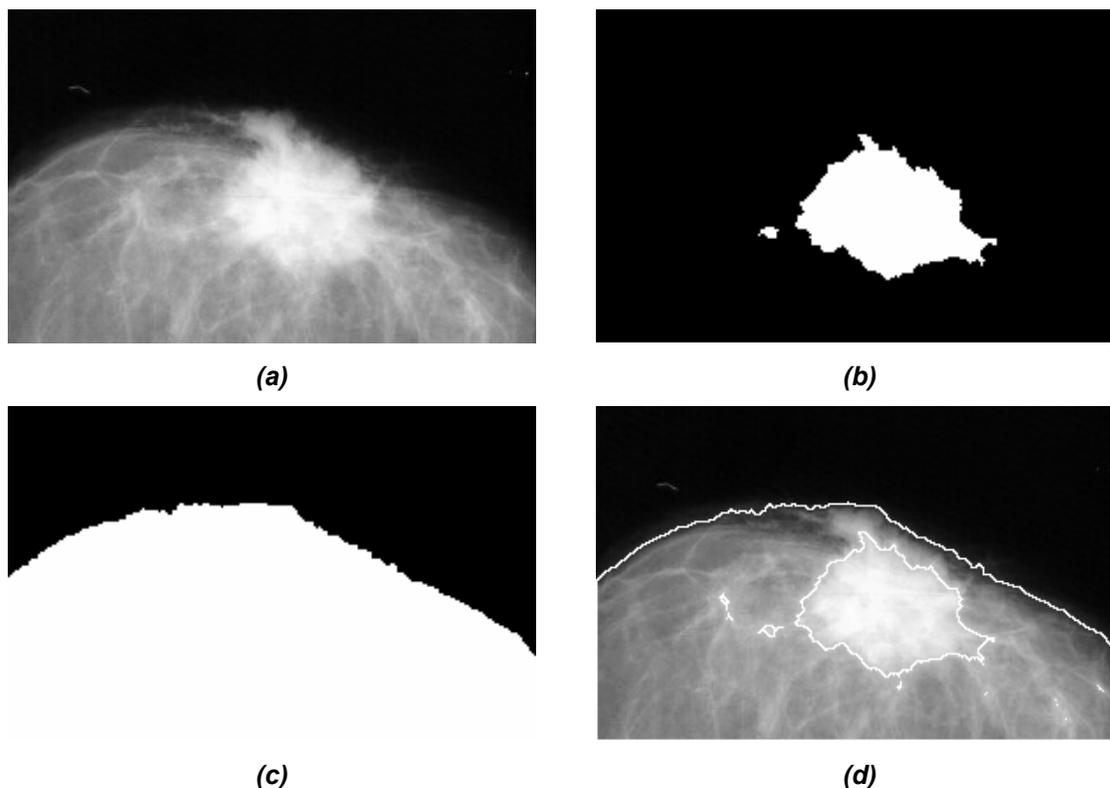


Figura 6.8. Segmentación de la mamografía de la Figura 6.3(b)
a) Imagen original, b) Marcación del objeto detectado, c) Marcación del seno
d) Delimitación de las regiones de interés encontradas en la mamografía original.

En estos resultados no se muestra la segmentación de las dos regiones de interés de la Figura 6.3(a), porque en esta imagen no se puede apreciar el contorno del seno. Esto da como resultado una imagen en la que se tiene el objeto detectado, y aparte la imagen tiene un borde blanco, mismo que delimita al seno.

Para probar el resultado de la segmentación en imágenes de mayor resolución, se tomó una mamografía de 1024x1024 píxeles en la que se tiene un tumor cancerígeno. Esta imagen fue tomada de la colección de imágenes de MIAS [5],

de la cual se hace una breve reseña en el Anexo C “Colección de Imágenes de Mamografía”.

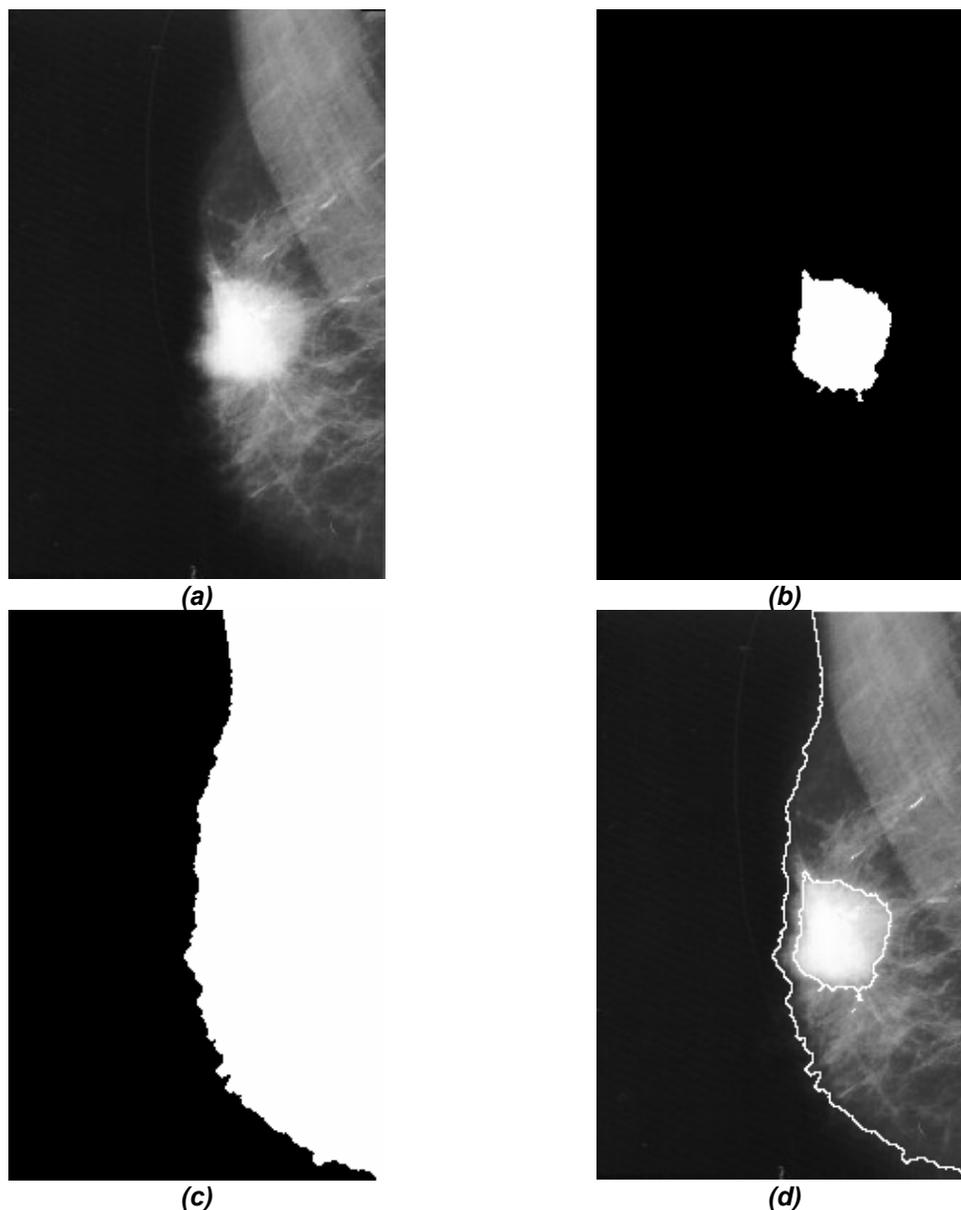


Figura 6.9. Segmentación de una mamografía de la Figura 6.3(c)
a) Imagen original, b) Marcación del objeto detectado, c) Marcación del seno
d) Delimitación de las regiones de interés encontradas en la mamografía original.

En la Figura 6.10 se aprecia la segmentación del seno y del tumor cancerígeno en la imagen de alta resolución. Además se observa que los resultados obtenidos son similares a los que se muestran en las Figuras 6.8 y 6.9.

Para el caso de la segmentación del seno, en la imagen original hay parte de éste que no es tomada en cuenta, aunque dada la variabilidad de luminosidad

de una mamografía a otra, se considera que aún en estos casos el umbral escogido es bueno para segmentar la Región 1(seno o mama).

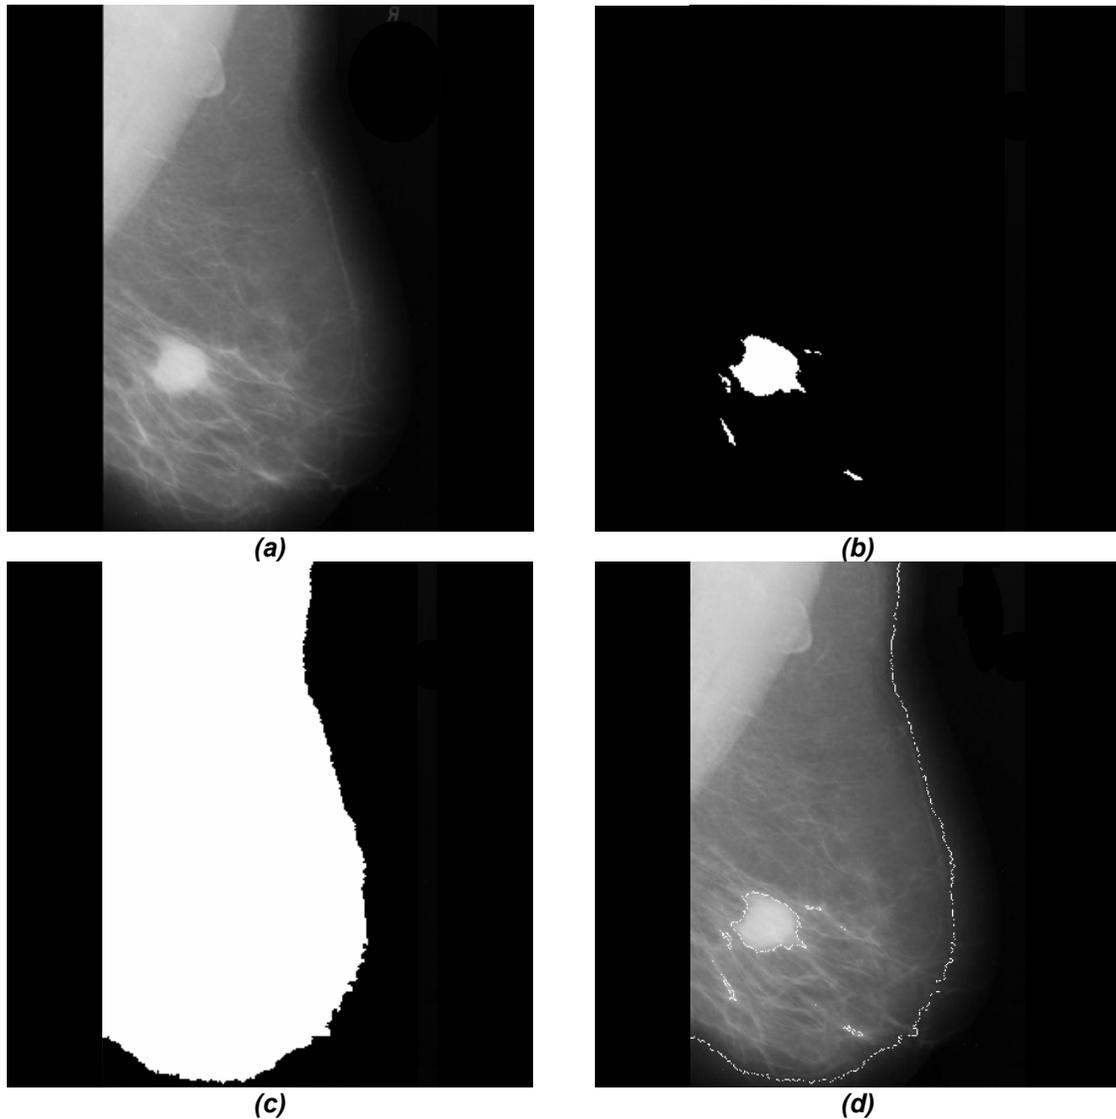


Figura 6.10. Segmentación de una mamografía de mayor resolución.
*a) Imagen original, b) Marcación del objeto detectado, c) Marcación del seno
d) Delimitación de las regiones de interés encontradas en la mamografía original.*

6.3 DATOS DE PRUEBA

Para hacer pruebas de segmentación se hizo una base de datos con las características geométricas y estadísticas extraídas de 32 imágenes que fueron

seleccionadas de la referencia [5]. Los datos que se usaron se agruparon de la siguiente manera:

1. *Mamografías normales (8 imágenes)*, que son aquellas imágenes en las que no se presenta ninguna anormalidad, y por consecuencia son sanas.
2. *Mamografías con anormalidades benignas (8 imágenes)*, en las que se encuentra alguna anormalidad que no es dañina.
3. *Mamografías con anormalidades malignas (8 imágenes)*, en las que se tiene una anormalidad cancerosa.
4. *Mamografías con microcalcificaciones benignas (4 imágenes)*, que son las imágenes en las que se encuentra(n) una(s) calcificación(es), pero el diagnóstico médico indica que ésta(s) no representa(n) un riesgo para la salud.
5. *Mamografías con microcalcificaciones malignas (4 imágenes)*, en las que, contrario al caso anterior, el diagnóstico indica que la(s) calcificación(es) son nocivas.

Las características obtenidas fueron:

Región 1 (seno o mama):

- Promedio
- Desviación estándar
- Rango

Región 2 (objeto detectado):

- Promedio
- Desviación estándar
- Rango
- Densidad de objeto

Y también se obtuvo el contraste entre las dos regiones, para dar un total de ocho características.

Para analizar las características obtenidas de cada grupo se hicieron dos gráficas de los resultados experimentales: en (a) se muestra la variación de

estos valores para tratar de ver qué comportamiento tiene cada característica en cada grupo de imágenes; y en (b) se muestra el valor promedio de las imágenes de cada grupo para una característica dada.

Los resultados de densidad de objeto se muestran en la Figura 6.11 y los resultados de contraste se presentan en la Figura 6.12.

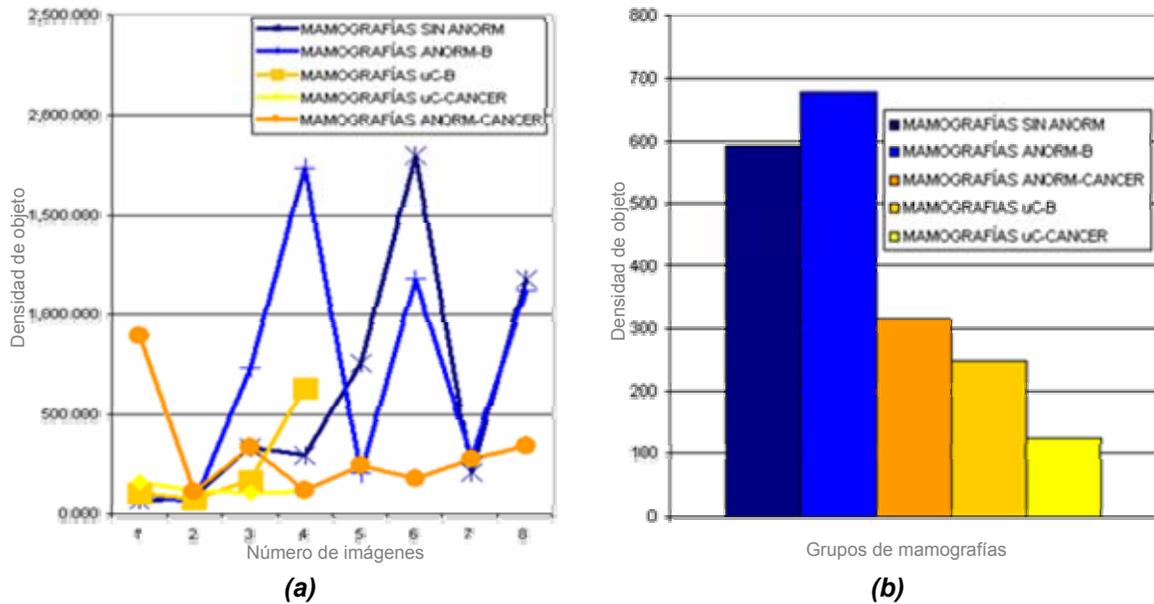


Figura 6.11. Densidad de objeto.

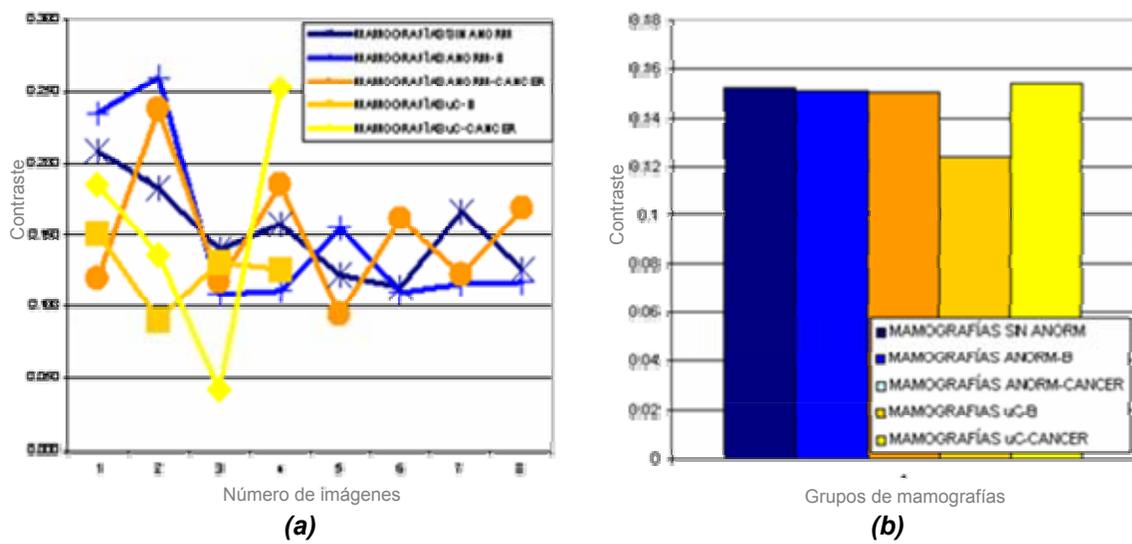


Figura 6.12. Contraste.

La desviación estándar del objeto detectado y de la mama se presentan en las Figuras 6.13 y 6.14, respectivamente.

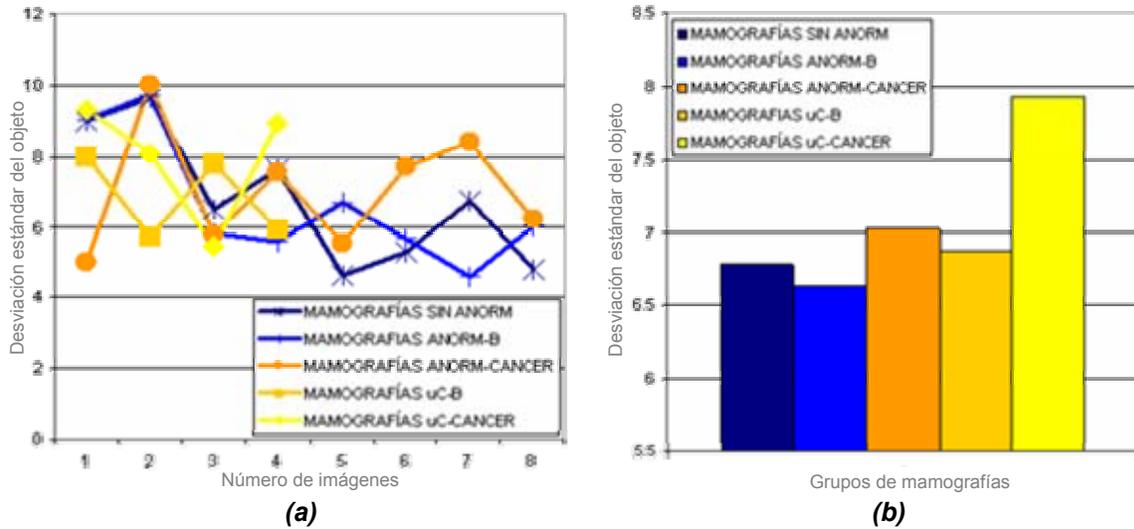


Figura 6.13. Desviación estándar del objeto.

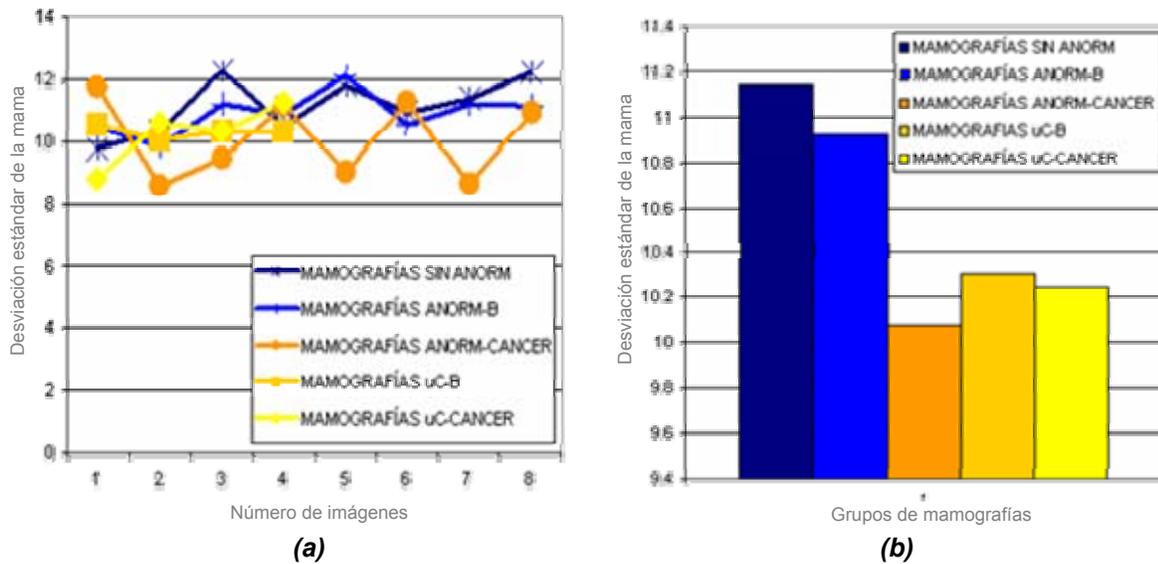


Figura 6.14. Desviación estándar del seno o mama.

La Figura 6.15 muestra el promedio del objeto y la Figura 6.16 presenta el promedio del seno o mama.

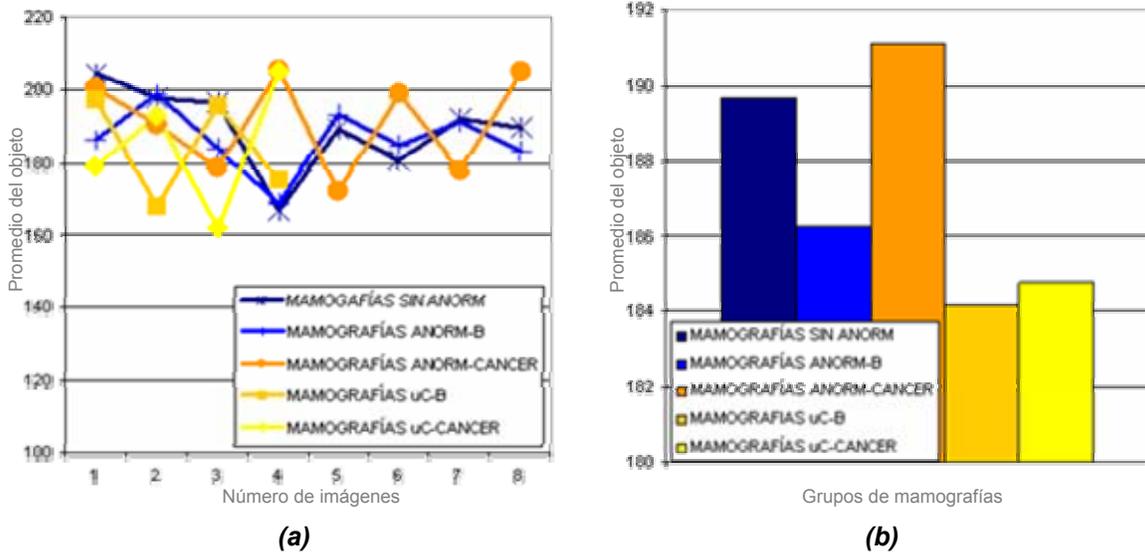


Figura 6.15. Promedio del objeto.

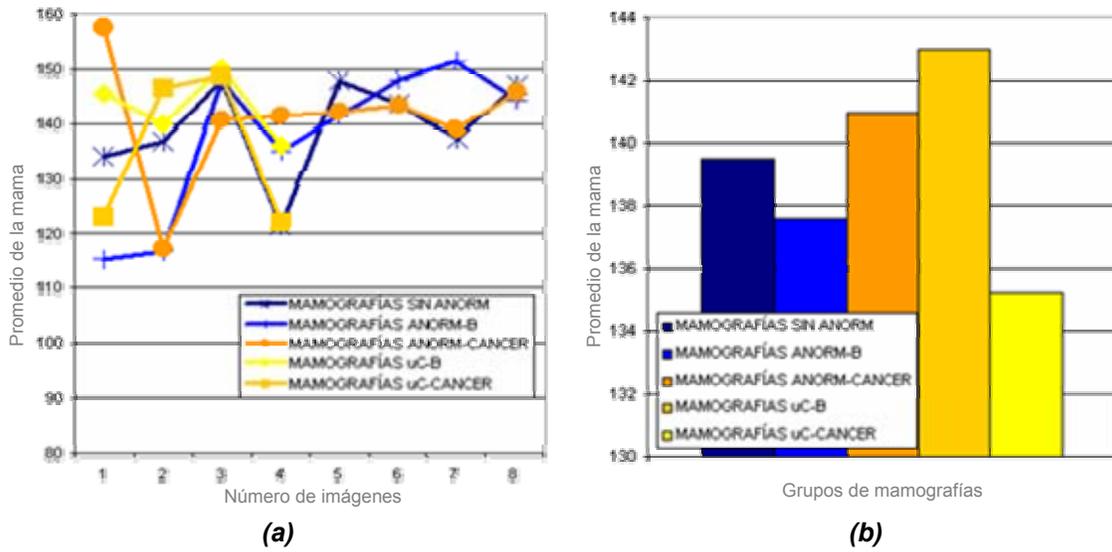


Figura 6.16. Promedio del seno o mama.

Los resultados de rango del objeto y rango de la mama se muestran en las Figuras 6.17 y 6.18, respectivamente.

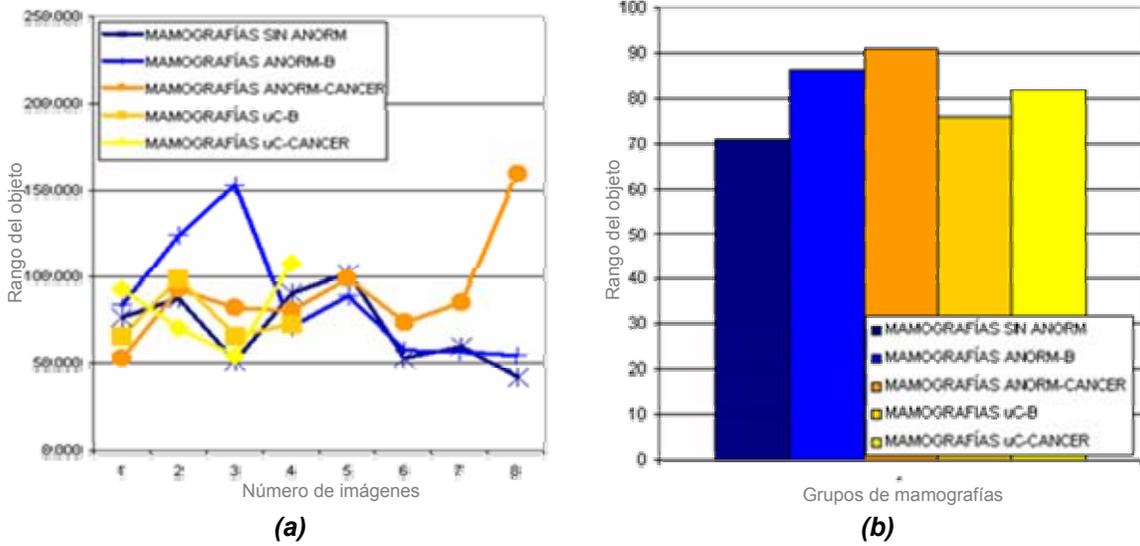


Figura 6.17. Rango del objeto.

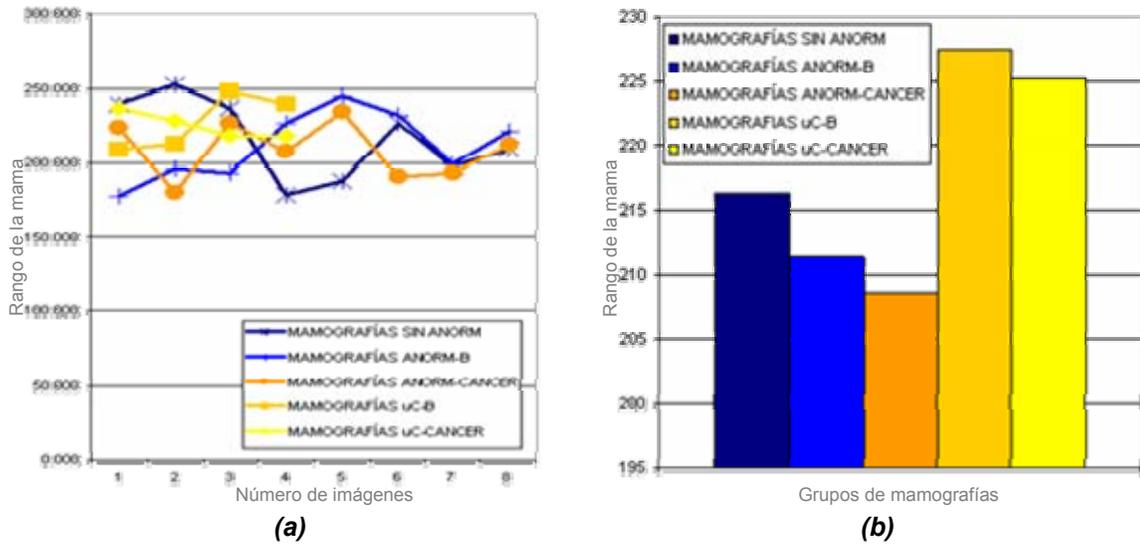


Figura 6.18. Rango del seno o mama.

De las Figuras 6.11(a), 6.12(a),..., 6.18(a), se puede ver que aún al haber extraído datos de dos regiones de interés ya delimitadas no se obtiene un valor uniforme para cada una de las características aquí presentadas. Aunque hay algunas de ellas que sí nos dan una idea de las diferencias entre imágenes, como se muestra en las barras azules y amarillas (ver Figuras 6.11(b), 6.12(b),..., 6.18(b)), como por ejemplo, las características de densidad de objeto,

desviación estándar de la mama y del objeto. Es por eso que en base a estos resultados se tomó la decisión de hacer la clasificación en dos grupos:

- Grupo 1, que está constituido por mamografías normales y con anomalías benignas, y
- Grupo 2, que se constituye de anomalías malignas y microcalcificaciones.

6.4 CLASIFICACIÓN

Después de haber obtenido los datos de las regiones de interés, se debe de implementar la Red Neuronal Artificial. Para el caso de esta tesis, se propone el uso de la Función de Base Radial en combinación con el estimador robusto MM, obteniendo así la Función de base Radial de Rango tipo M (RMRBF).

El primer paso es hacer una RBF de prueba, y posteriormente implementar la RMRBF y ver si la propuesta funciona. Después, basándose en el mismo principio, se debe de implementar una RMRBF usando como datos las características de las regiones de interés mencionadas en la sección 6.3 para clasificar imágenes de mamografía.

El diagrama de la RBF que se implementó en este trabajo se muestra en la Figura 6.19.

6.4.1 PRUEBAS DEL CLASIFICADOR

Para probar la eficiencia de la red propuesta, primeramente se probó con imágenes que tienen formas geométricas sencillas. Algunas de ellas se muestran en la Figura 6.20.

El objetivo de esta prueba es lograr clasificar en dos grupos principales:

- El Grupo A contiene círculos y elipses, que en la Figura 6.20 están denotados por letras minúsculas.
- El Grupo B contiene varios tipos de polígonos, que en la Figura 6.20 están denotados por letras mayúsculas.

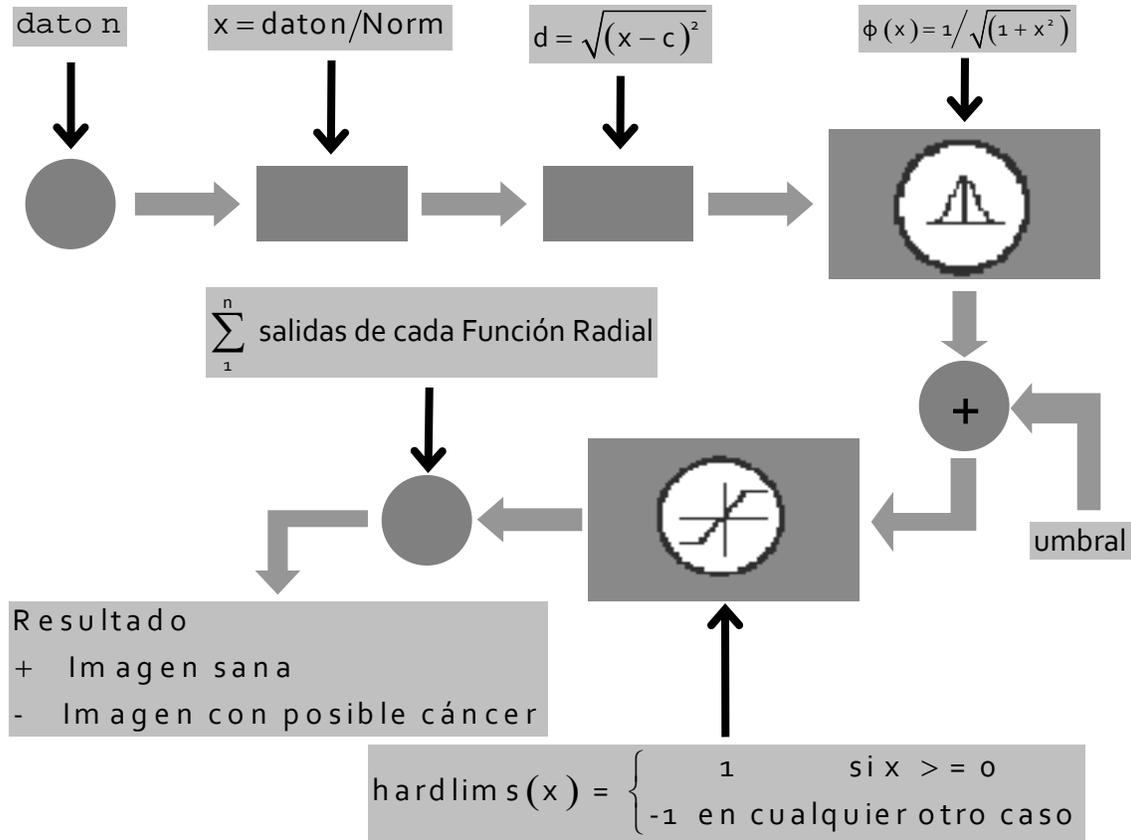


Figura 6.19. Diagrama de la RBF implementada.

Las primeras seis imágenes del Grupo A tienen un relleno o textura similar entre sí, que es distinto al relleno o textura de las primeras seis imágenes del Grupo B, y las últimas dos imágenes de cada grupo tienen un relleno o textura similar a la del grupo contrario. La idea principal de usar texturas en figuras es tratar de simular un poco la textura de las imágenes de mamografía.

En la etapa de segmentación se obtuvieron tres características o datos numéricos, que son la densidad de objeto, el promedio de nivel de gris y la desviación estándar.

Se emplearon diez imágenes para determinar los parámetros de la red neuronal (cinco de cada grupo), y los resultados del entrenamiento se muestran en la Tabla 6.3.

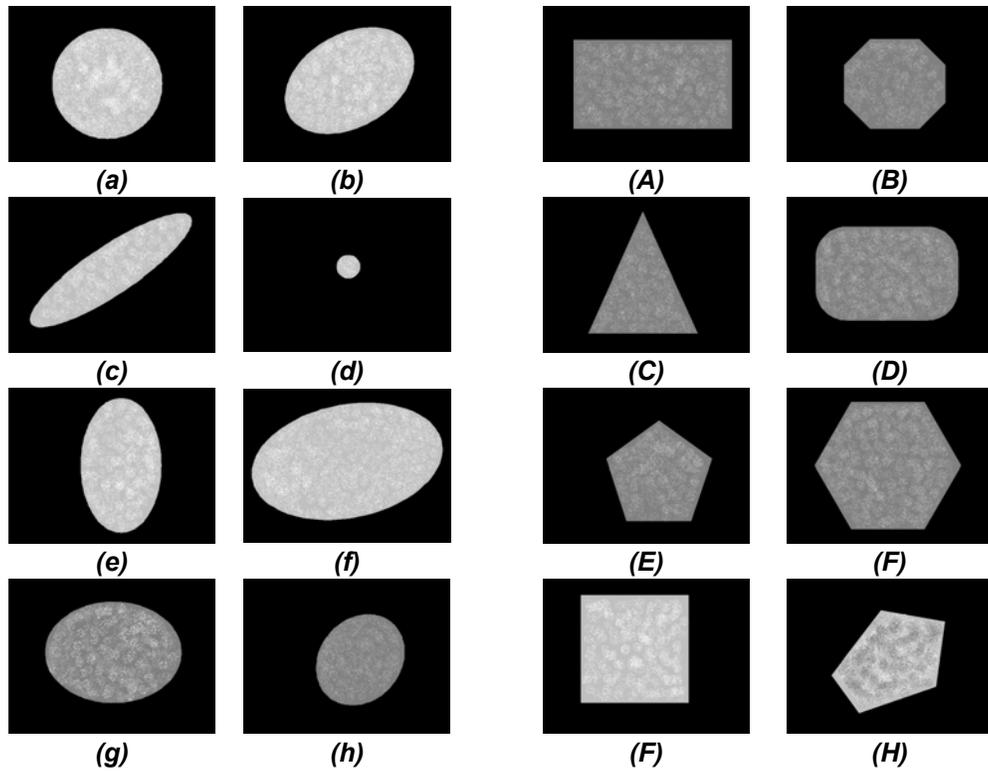


Figura 6.20. Imágenes de prueba.

Tabla 6.3. Entrenamiento de la RBF con formas geométricas sencillas.

		Grupo A	Grupo B	Total
RBF Simple	Eficiencia	60%	100%	80%
	Incertidumbre	0%	0%	0%
	Error	40%	0%	20%

El entrenamiento del clasificador se llevó a cabo conforme a lo visto en la sección 5.2.4: Usando las 3 características o datos numéricos de las imágenes de prueba obtenidos en la etapa de segmentación, se obtuvieron los centros de las funciones radiales usando el algoritmo de las k-medias. Posteriormente se ajustaron las amplitudes de cada una de las funciones radiales de manera experimental. Para el caso de este trabajo, las funciones radiales usadas fueron multicuadráticas inversas (Ecuación 5.6), pues en simulaciones realizadas mostraron mejores resultados. La Figura 6.21 muestra el procedimiento mencionado para entrenar a la RBF.

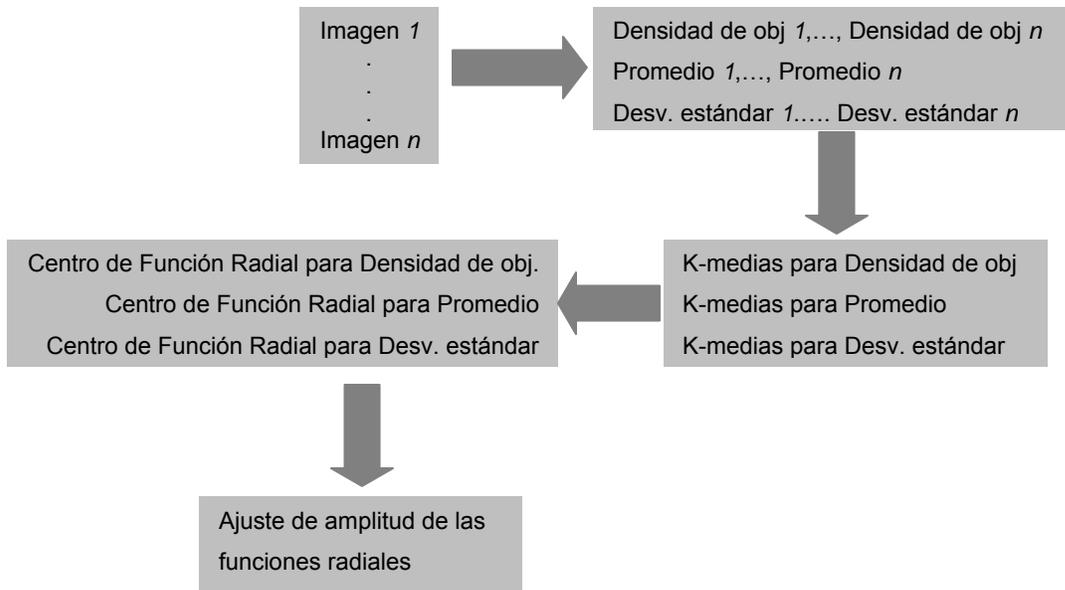


Figura 6.21. Diagrama del entrenamiento de la RBF.

Para la fase de prueba de la red se emplearon 30 imágenes (15 de cada grupo) distintas a las empleadas en la fase de entrenamiento. Los resultados obtenidos se muestran en la Tabla 6.4.

Tabla 6.4. Prueba de la RBF con formas geométricas sencillas.

		Grupo A	Grupo B	Total
RBF Simple	Eficiencia	67%	93%	80%
	Incertidumbre	0%	0%	0%
	Error	33%	7%	20%

Para tratar de incrementar la eficiencia de la Red Neuronal, ahora se emplean algunos métodos de estadística robusta vistos en la sección 5.3 para obtener la RMRBF. Se usa el estimador MM (Ecuación 5.12) en combinación con el algoritmo de las k-medias para la estimación de los centros de las funciones radiales, y se usan las funciones de influencia Simple Cut (Ecuación 5.10) y Tukey (Ecuación 5.11) para procesar los datos obtenidos con el estimador MM. El procedimiento para entrenar la red es el mismo que se empleó en la red anterior (Figura 6.21).

Los resultados del entrenamiento y de la fase de prueba se muestran en las Tablas 6.5 y 6.6, respectivamente.

Tabla 6.5. Entrenamiento de la RMRBF con formas geométricas sencillas.

		Grupo A	Grupo B	Total
RBF Simple Cut	Eficiencia	67%	100%	83.5%
	Incertidumbre	0%	0%	0%
	Error	33%	0%	16.5%
RBF Tukey	Eficiencia	67%	100%	83.5%
	Incertidumbre	0%	0%	0%
	Error	33%	0%	16.5%

Tabla 6.6. Prueba de la RMRBF con formas geométricas sencillas

		Grupo A	Grupo B	Total
RBF Simple Cut	Eficiencia	67%	100%	83.5%
	Incertidumbre	0%	0%	0%
	Error	33%	0%	16.5%
RBF Tukey	Eficiencia	67%	100%	83.5%
	Incertidumbre	0%	0%	0%
	Error	33%	0%	16.5%

Se puede apreciar que mediante el uso de las funciones de influencia no se tiene una mejora en la fase de entrenamiento, pero sí en la fase de prueba, que es la más importante, pues esto nos hace suponer que se va a tener estabilidad en el desempeño de la red, queriendo decir con esto que la eficiencia en la fase de prueba no difiere mucho de la eficiencia en la fase de entrenamiento.

Cabe señalar que aunque los porcentajes de eficiencia coinciden en las dos fases (prueba y entrenamiento) no significa que siempre se vaya a dar este caso.

Habiendo probado el funcionamiento de la red propuesta, el paso siguiente es probarla para clasificar imágenes de mamografía.

6.4.2 IMPLEMENTACIÓN DEL CLASIFICADOR

Para comparar el rendimiento de la red neuronal propuesta (RMRBF), se implementaron dos algoritmos relacionados con la RBF: α -Trimmed Mean RBF y Median RBF, las cuales fueron implementadas de acuerdo a sus referencias bibliográficas [6,7,8].

Los datos usados para entrenar a las RBF implementadas son las características numéricas obtenidas en la sección 6.3, que fueron obtenidos de 32 imágenes. Para probar la eficiencia de las diversas RBF's se usaron un total de 125 imágenes obtenidas de la colección de imágenes MIAS [5] distribuidas en cinco casos principales:

- 40 imágenes que pertenecen al grupo de mamografías sin anomalías o sanas, (NORMAL).
- 38 imágenes que pertenecen al grupo de mamografías con diversas anomalías benignas (AN_BEN).
- 30 imágenes que pertenecen al grupo de mamografías con diversas anomalías malignas (AN_MAL).
- 8 imágenes que pertenecen al grupo de mamografías con microcalcificaciones (μ C) benignas (uC_BEN).
- 9 imágenes que pertenecen al grupo de mamografías con μ C malignas (uC_MAL).

La clasificación de las imágenes se lleva a cabo conforme a los dos grupos obtenidos en la sección 6.3: Grupo 1 (mamografías normales y con anomalías benignas) y Grupo 2 (anomalías malignas y microcalcificaciones).

Las imágenes usadas para estas pruebas fueron tomadas principalmente de la referencia [5], pues varios trabajos relacionados con el análisis digital de imágenes de mamografía se basan en esta colección de imágenes.

El procedimiento para entrenar las Redes Neuronales Artificiales implementadas es el mismo que se muestra en la Figura 6.21, variando el número de características, que en este caso son 8, y los datos empleados para calcular los centros de las funciones radiales de acuerdo a las referencias citadas[6,7,8].

En la Tabla 6.7 se muestran los resultados experimentales en términos de eficiencia, incertidumbre y error para la colección de imágenes de mamografía para los cinco casos principales: normales (NORMAL), anomalías benignas (AN_BEN), anomalías malignas (AN_MAL), microcalcificaciones benignas

(uC_BEN), y microcalcificaciones malignas (uC_MAL) para el caso de diferentes RBF.

Tabla 6.7. Resultados de rendimiento mediante el uso de diferentes redes neuronales.

Redes Neuronales		NORMAL	AN_BEN	AN_MAL	uC_BEN	uC_MAL	TOTAL
SIMPLE RBF	Eficiencia	52.50%	47.37%	30.00%	12.50%	55.56%	39.59%
	Incertidumbre	1.33%	0.00%	0.00%	0.00%	0.00%	0.27%
	Error	46.17%	52.63%	70.00%	87.50%	44.44%	60.15%
MEDIANA RBF	Eficiencia	65.00%	60.53%	26.67%	12.50%	66.67%	46.27%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	35.00%	39.47%	73.33%	87.50%	33.33%	53.73%
α -TRIMMED MEAN RBF	Eficiencia	47.50%	57.89%	50.00%	87.50%	55.56%	59.69%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	52.50%	42.11%	50.00%	12.50%	44.44%	40.31%
RMRBF Simple Cut	Eficiencia	70.00%	71.05%	30.00%	62.50%	88.89%	64.49%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	30.00%	28.95%	70.00%	37.50%	11.11%	35.51%
RMRBF Tukey	Eficiencia	70.00%	57.89%	36.67%	37.50%	77.78%	55.97%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	30.00%	42.11%	63.33%	62.50%	22.22%	44.03%

De la Tabla 6.7 se puede apreciar que la eficiencia de la RMRBF usando la función de influencia Simple Cut es la que presenta mejores resultados.

Los rendimientos de cada una de las redes neuronales implementadas también se pueden apreciar de manera gráfica en las Figuras 6.21 a 6.25.

En la Figura 6.22 se puede ver la eficiencia de clasificación para cada uno de los grupos propuestos para la RBF simple. Se aprecia que el error para el grupo 2 es grande, lo que lleva a la conclusión de que el algoritmo simple de esta red no es bueno por sí solo para clasificar las imágenes con el tipo de datos obtenidos en la etapa de segmentación.

En la Figura 6.23 se aprecia que la Median RBF presenta mejores capacidades de clasificación que en el caso anterior (ver Figura 6.22), aunque en el grupo 2 aún se tienen una cantidad importante de error.

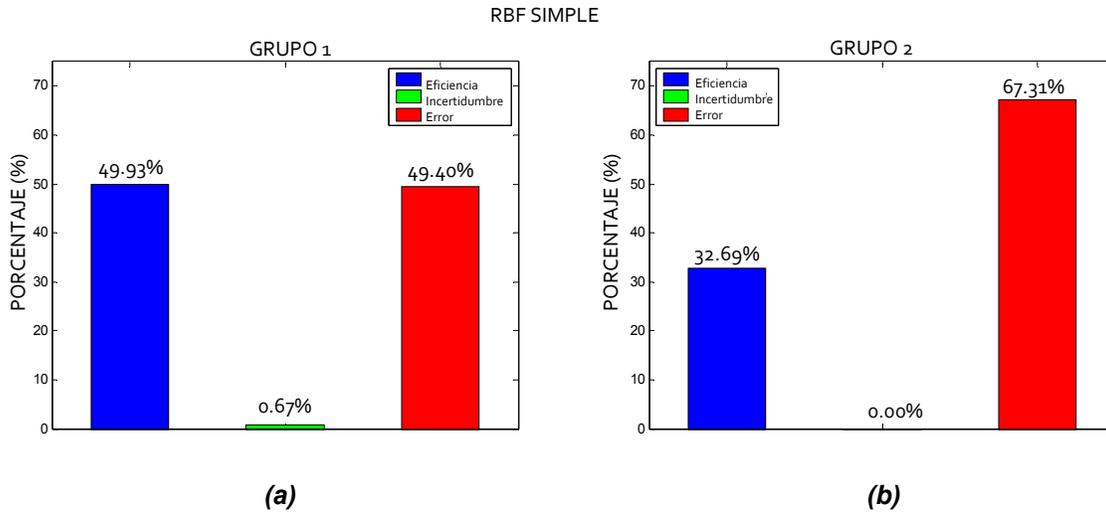


Figura 6.22. Eficiencia de la RBF simple. a) Grupo 1, imágenes normales y con anomalías benignas, b) Grupo 2, cualquier tipo de microcalcificación y anomalías malignas.

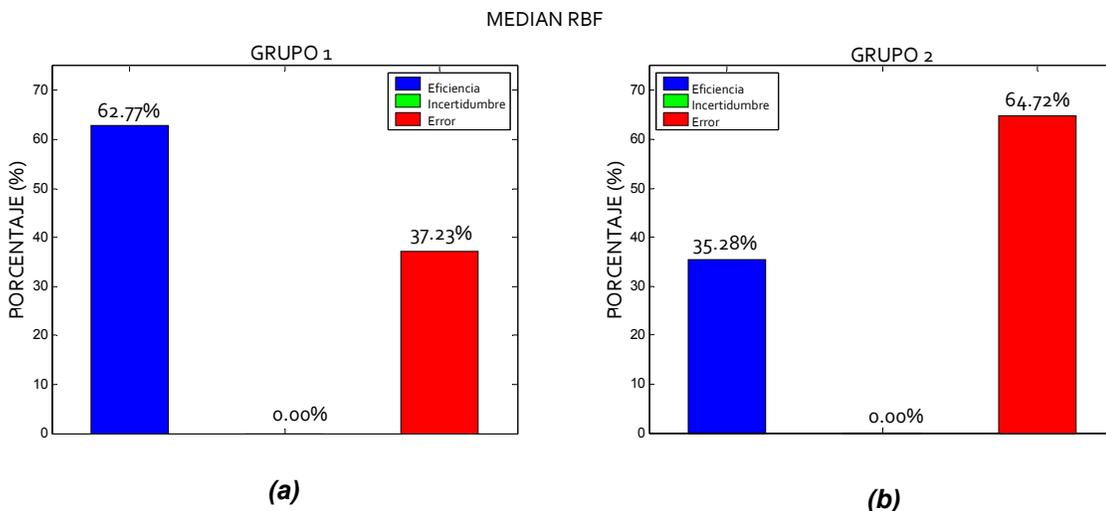


Figura 6.23. Eficiencia de la Median RBF a) Grupo 1, imágenes normales y con anomalías benignas, b) Grupo 2, cualquier tipo de microcalcificación y anomalías malignas.

En la Figura 6.24 se muestran los resultados obtenidos con la red α -Trimmed Mean RBF, y se observa que aunque la eficiencia de clasificación del Grupo 1 decreció un poco, alrededor de un 10%, la eficiencia de clasificación del Grupo 2 subió casi 30%. Esto lleva a la conclusión de que los algoritmos encontrados en la literatura, éste es el que presenta mayores capacidades de clasificación para los propósitos de este trabajo.

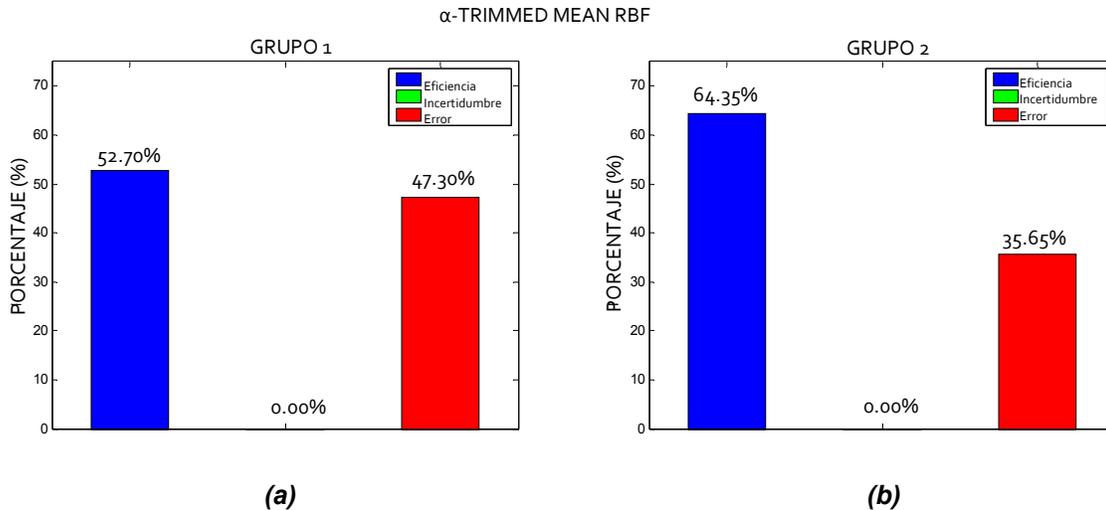


Figura 6.24. Eficiencia de la α -trimmed mean RBF a) Grupo 1, imágenes normales y con anomalías benignas, b) Grupo 2, cualquier tipo de microcalcificación y anomalías malignas.

En la Figura 6.25 se muestran los resultados obtenidos con la RMRBF usando la función de influencia Simple Cut. La clasificación de las imágenes del Grupo 1 es mayor al 70%, más alta que cualquiera de los casos anteriores. Aunque la eficiencia de clasificación para el Grupo 2 es un poco menor a la obtenida en el caso anterior, el rendimiento de esta red, que es de un 64.49%, es mayor que las obtenidas con los métodos encontrados en la literatura.

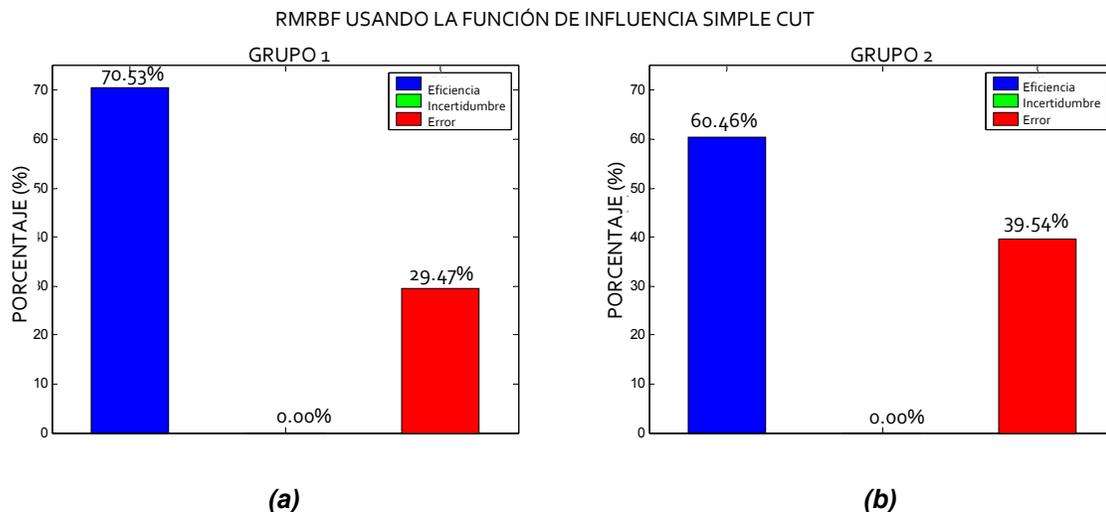
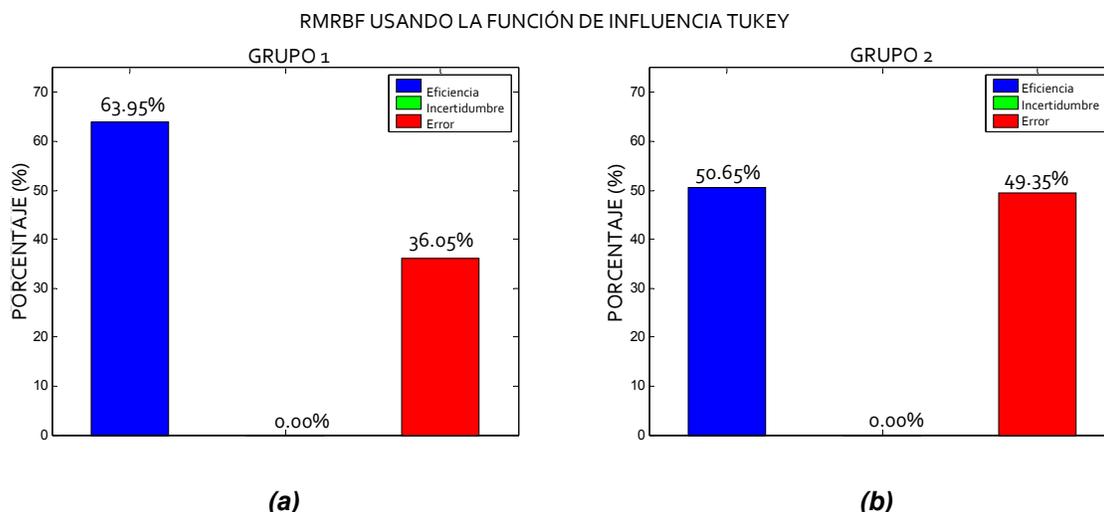


Figura 6.25. Eficiencia de la RMRBF (Simple Cut) a) Grupo 1, imágenes normales y con anomalías benignas, b) Grupo 2, cualquier tipo de microcalcificación y anomalías malignas.

En la Figura 6.26 se muestran los resultados obtenidos con la RMRBF usando la función de influencia Tukey. La eficiencia es un poco menor que la obtenida con el algoritmo de α -Trimmed Mean RBF, ya que para este caso la eficiencia de la RMRBF es de un 55.97%, mientras que la de la α -Trimmed Mean RBF es de 59.64%.



(a) (b)
Figura 6.26. Eficiencia de la RMRBF (Tukey). a) Grupo 1, imágenes normales y con anomalías benignas, b) Grupo 2, cualquier tipo de microcalcificación y anomalías malignas.

La eficiencia de clasificación para el Grupo 1 y el Grupo 2 se muestra de manera resumida en la Tabla 6.8.

Tabla 6.8. Resultados de rendimiento en el Grupo 1 y en el Grupo 2.

Redes Neuronales	Grupo 1			Grupo 2		
	Eficiencia	Incertidumbre	Error	Eficiencia	Incertidumbre	Error
SIMPLE RBF	49.93%	0.67%	49.40%	32.69%	0.00%	67.31%
MEDIANA RBF	62.77%	0.00%	37.23%	35.28%	0.00%	64.72%
α -TRIMMED MEAN RBF	52.70%	0.00%	47.30%	64.35%	0.00%	35.65%
RMRBF Corte simple	70.53%	0.00%	29.47%	60.46%	0.00%	39.54%
RMRBF Tukey	63.95%	0.00%	36.05%	50.65%	0.00%	49.35%

6.5 SENSITIVIDAD Y ESPECIFICIDAD

6.5.1 SENSITIVIDAD

La sensibilidad es la probabilidad de que un examen médico entregue un resultado positivo cuando se tiene un grupo de pacientes con cierta enfermedad que se está estudiando. La fórmula para calcular la sensibilidad es [10]:

$$S_n = TP / (TP + FN) \quad (6.1)$$

Donde S_n representa la sensibilidad, TP el número de resultados positivos correctos y FN el número de falsos negativos, esto es, de resultados negativos que no son correctos.

6.5.2 ESPECIFICIDAD

La especificidad es la probabilidad de que un examen médico entregue un resultado negativo cuando se tiene un grupo de pacientes que no presentan la enfermedad que se está estudiando. La fórmula para calcular la especificidad es [10]:

$$S_p = TN / (TN + FP) \quad (6.2)$$

Donde S_p representa la especificidad, TN el número de resultados negativos correctos y FP el número de falsos positivos, esto es, de resultados positivos incorrectos.

En la Tabla 6.9 se muestran la sensibilidad y la especificidad para cada una de las redes neuronales implementadas.

Tabla 6.9. Sensitividad y especificidad de las Redes Neuronales implementadas.

Redes Neuronales	Sensitividad	Especificidad
SIMPLE RBF	34.04%	50.00%
MEDIANA RBF	31.91%	62.82%
α -TRIMMED MEAN RBF	57.45%	52.56%
RMRBF Corte simple	48.93%	70.51%
RMRBF Tukey	44.68%	64.10%

6.6 TIEMPOS DE PROCESAMIENTO

En la etapa experimental se observó que el tiempo necesario para segmentar una imagen de mamografía varía de acuerdo a varios factores: la resolución de la imagen, el tamaño del objeto detectado, etc. Este tiempo puede tomar desde unos segundos hasta horas.

El tiempo de extracción de características es breve, pues sólo se tienen que hacer cálculos numéricos sencillos.

El equipo que se utilizó para hacer pruebas fue una Work Station PC Dell® Precision 380, que cuenta con un procesador Intel® Pentium 4 a 3 GHz y 2 GB de RAM.

El tiempo se midió en 65 imágenes usadas en la parte de prueba del programa computacional, y se encontraron los valores que se muestran en las Tablas 6.10, 6.11 y 6.12.

Tabla 6.10. Tiempos de segmentación y extracción de características.

	Minutos
Tiempo promedio	30.307
Tiempo máximo	120.334
Tiempo mínimo	6.781

Tabla 6.11. Tiempos de clasificación.

	Segundos
Tiempo promedio	2.672
Tiempo máximo	12.469
Tiempo mínimo	2.203

Tabla 6.12. Porcentajes totales de tiempo (promedio).

Etapa o fase	Porcentaje
Segmentación y extracción de características	99.85%
Clasificación	0.15%

6.7 CONCLUSIONES

La segmentación propuesta entrega buenos resultados para las imágenes de distintas resoluciones usadas en la etapa de prueba, aunque se puede apreciar que la segmentación por sí sola no proporciona datos suficientes para poder clasificar una imagen de mamografía.

Se propuso un nuevo tipo de red neuronal llamada Función de base Radial de Rango tipo M (RMRBF) para la clasificación de imágenes de mamografía.

Los resultados obtenidos con RMRBF propuesta son mejores que los resultados obtenidos mediante el uso de los algoritmos consultados, como se muestra en la Tabla 6.13

Tabla 6.13. Porcentaje de mejora en la eficiencia de la RMRBF con las funciones de influencia utilizadas con respecto a los algoritmos de la RBF consultados en la literatura.

Redes Neuronales	SIMPLE RBF	MEDIANA RBF	α -TRIMMED MEAN RBF
RMRBF Corte simple	24.90%	18.22%	4.80%
RMRBF Tukey	16.38%	9.70%	-3.72%

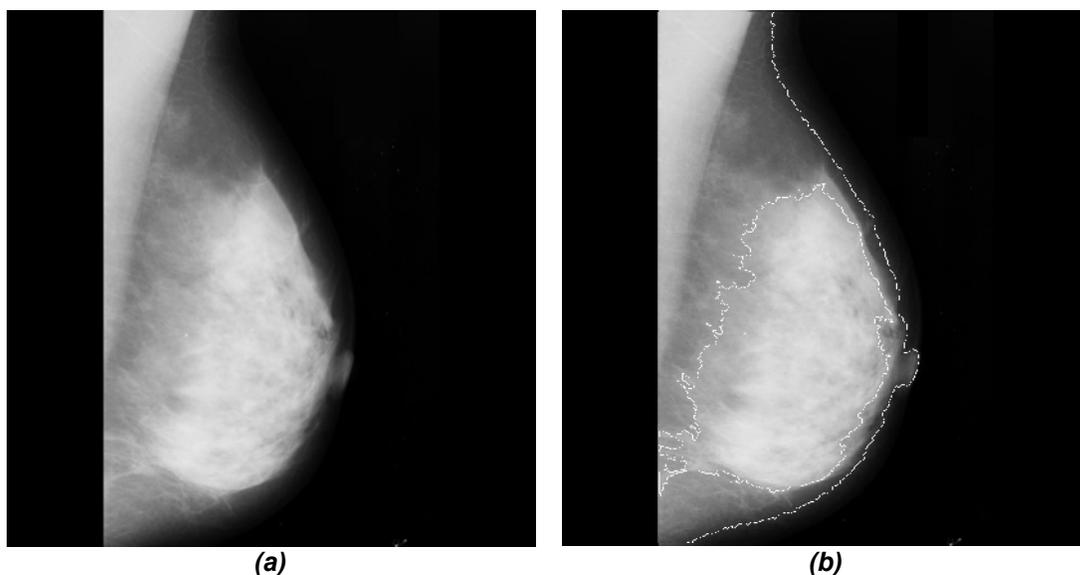
En la tabla anterior se puede apreciar que la RMRBF con la función de influencia de Corte Simple es la que presenta mayor eficiencia; al usar la función de influencia Tukey, la eficiencia es menor, incluso se tiene una eficiencia menor que la red α -Trimmed Mean RBF, que supera a RMRBF, para este caso, en casi un 4%.

La mayoría de las aplicaciones de análisis digital de mamografías se ha enfocado en la detección de microcalcificaciones, pues éstas son técnicamente más sencillas de detectar que otras masas con diversas distorsiones [11]. Comparando el resultado obtenido con otras referencias que usan la misma colección de imágenes se tiene lo siguiente:

- La referencia [12] reporta una eficiencia en la fase de entrenamiento de 62.45% en clasificación de microcalcificaciones usando una red neuronal de retropropagación. El número de imágenes usado fue de 50.

El programa computacional propuesto en este trabajo no sólo clasifica microcalcificaciones, sino que también, en los 2 grupos propuestos, considera la clasificación de tumores cancerosos.

Un problema importante a considerar es que las imágenes de mamografía presentan formas muy irregulares y que pueden causar resultados erróneos. En la Figura 6.27 se muestra una mamografía que la red propuesta clasificó correctamente, y la Figura 6.28 muestra una mamografía que se clasificó incorrectamente.



*Figura 6.27. Imagen de mamografía con un resultado correcto.
a) Original, b) Segmentada.*

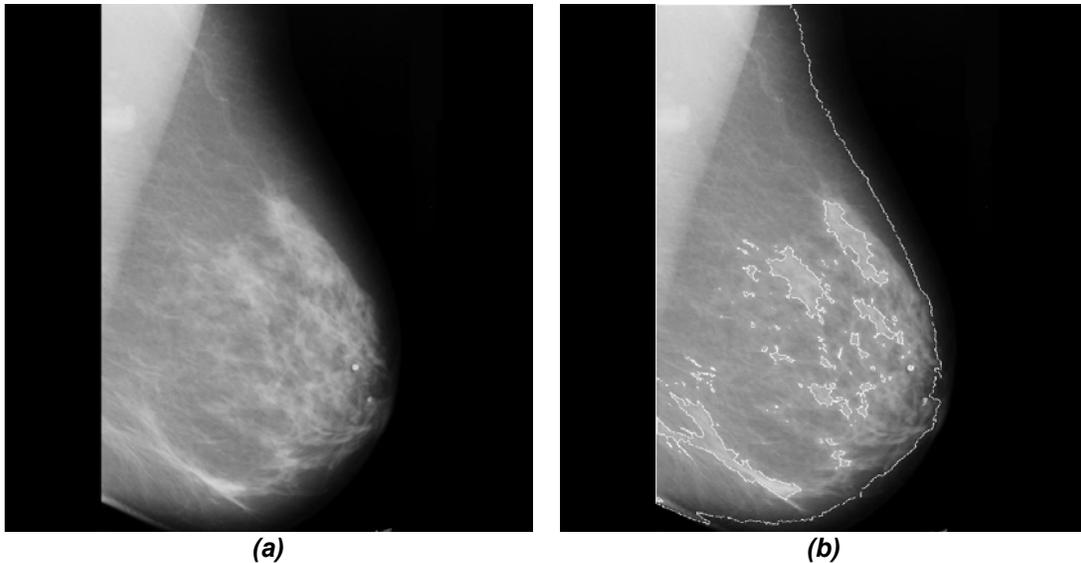


Figura 6.28. Imagen de mamografía con un resultado incorrecto.
a) Original, b) Segmentada.

6.8 REFERENCIAS

- [1] R. C. González, R. E. Woods, “Tratamiento Digital de Imágenes”, Addison Wesley/Díaz de Santos, 1996. Páginas 447-482.
- [2] Matlab 7.0 Image Processing Toolbox.
- [3] <http://members.tripod.com/~gineco>
- [4] www.opolanco.es
- [5] <http://www.wiau.man.ac.uk/services/MIAS/MIAScom.html>
- [6] Adrian G. Bors, Ioannis Pitas, “Object Classification in 3D images using Alpha Trimmed Mean Radial Basis Function Network”. IEEE Trans. Image Processing, 8, 1730-1744, 1999.
- [7] Adrian G. Bors, Ioannis Pitas, “Median Radial Basis Function Neural Network”, IEEE Trans. Neural Networks, 7(6), 1351-1364, 1996.
- [8] Adrian G. Bors, Ioannis Pitas, “Robust RBF Networks”. Chapter 10. Adrian Bors’s Book Chapters, University of York, UK.
- [9] Neural Network Toolbox, Matlab 7.0.
- [10] <http://www.cmh.edu/stats/definitions/>

- [11] Predrag R. Bakic y Dragana P. Brzakovic, "Application of Neural Networks in Computer Aided Diagnosis of Breast Cancer". IEEE Transactions on Medical Imaging. 2002.
- [12] Samuel Oporto, Rolando Hernández, Hugo Terashima, "Detección de Microcalcificaciones en Imágenes de Mamografías Usando Diferencia de Filtros Gaussianos Optimizados". XXX Conferencia Latinoamericana de Informática CLEI 2004.

CAPÍTULO 7

CONCLUSIONES GENERALES

Y TRABAJO FUTURO

7.1 CONCLUSIONES

- La detección del cáncer de mama en etapas tempranas es muy importante, pues de esto depende en gran medida la vida de la persona que tenga este padecimiento. Un método muy común para examinar los senos es la mamografía, la cual permite detectar tumores o quistes muy pequeños.
- El cáncer de mama es uno de las causas de muerte más importantes en la población femenina de nuestro país, incluso existen muchas campañas a nivel nacional para generar conciencia de lo importante que es este mal.
- La segmentación de las imágenes de mamografía es el punto de partida para poder llevar a cabo la clasificación de las mismas. De las técnicas de segmentación de imágenes digitales consultadas en la bibliografía, se encontró la segmentación morfológica combinada con técnicas de selección de umbral permite dividir las imágenes de mamografía de manera automática.
- Las partes en las que se divide la imagen pueden ser analizadas usando algunas técnicas de medición geométrica, pero también se pueden utilizar algunas cantidades estadísticas.
- Las Redes Neuronales Artificiales (RNA) son sistemas de reconocimiento que pueden generalizar aprendiendo de ejemplos, y se pueden implementar computacionalmente como clasificadores, entre otras cosas. Su funcionamiento se asemeja en mucho al de las Neuronas biológicas: conexiones entre neuronas, umbrales de activación, etc.

- Existe una gran diversidad de RNA. Una manera común de clasificarlas es conforme a su arquitectura o topología, aunque también se pueden clasificar de acuerdo a la manera en que se implementan, esto es, de acuerdo a cómo estas redes son entrenadas. De la gran variedad RNA existentes, algunas implican mayores cálculos matemáticos que otras, y por ende, mayor complejidad para ser implementadas en un programa computacional.
- La RNA Función de Base Radial es un buen clasificador que se puede implementar de manera sencilla, y se puede hacer uso de la estadística robusta para tratar de mejorar su rendimiento.
- Se propuso un nuevo tipo de red neuronal llamada Función de base Radial de Rango tipo M (RMRBF) para la clasificación de imágenes de mamografía. Los resultados obtenidos con RMRBF propuesta son mejores alrededor de un 4% que los resultados obtenidos mediante el uso de los algoritmos consultados. Incluso, con la misma colección de imágenes, presenta un mejor rendimiento que otros métodos reportados.
- La mayoría de las aplicaciones de análisis digital de mamografías se ha enfocado en la detección de microcalcificaciones, pues éstas son técnicamente más sencillas de detectar que otras masas con diversas distorsiones. El programa computacional propuesto en este trabajo no sólo clasifica microcalcificaciones, sino que también, en los 2 grupos propuestos, considera la clasificación de tumores cancerosos.
- Aunque la propuesta funcionó y fue mejor que sus comparativos, aún se tiene un porcentaje considerable cercano al 35%. Un problema importante a considerar es que las imágenes de mamografía presentan formas muy irregulares y que pueden causar resultados erróneos.

7.2 TRABAJO FUTURO

Para mejorar la eficiencia del sistema se debe de:

- Probar otro método de segmentación de imágenes para obtener datos más precisos acerca de las regiones donde se pueden encontrar tumores cancerígenos o microcalcificaciones y así poder incrementar la especificidad y sensibilidad del sistema para propósitos de uso práctico.
- Hacer pruebas con otros tipos de estimadores R en el esquema de la red neuronal RMRBF para mejorar las capacidades de clasificación de la red propuesta.

ANEXOS

- A. ALGORITMO DE LAS K-MEDIAS,
- B. GLOSARIO
- C. COLECCIÓN DE IMÁGENES DE MAMOGRAFÍA
- D. PROGRAMAS EN MATLAB
- E. PUBLICACIONES Y CONGRESOS

ALGORITMO DE LAS K-MEDIAS

El algoritmo de las k -medias fue descrito por primera vez por J. B. MacQueen [1]. Es uno de los algoritmos para clasificación no supervisada más simple. El algoritmo parte de un número determinado de prototipos, y de un conjunto de muestras a agrupar, sin etiquetar. La idea es situar a los prototipos en el espacio, de forma que los datos pertenecientes al mismo prototipo tengan características similares.

Este algoritmo requiere un único parámetro, k , el número de agrupamientos que debe encontrar. Puede plantearse en tres pasos [1,2,3]:

1. Inicialización. Consiste en inicializar arbitrariamente los centros de los k grupos.
2. Asignación y actualización de los centros. Se asigna cada patrón al grupo más cercano y se recalculan los centros en base a esta asignación.
3. Convergencia. En el paso anterior algunos patrones pueden cambiar de agrupamiento y en consecuencia, los centros de éstos. Si ésto ocurre, se trata de repetir el paso 2 hasta que no se modifiquen los centros. Cuando no hayan modificaciones se considera que se ha encontrado una buena partición y se termina el agrupamiento.

Por esta razón se incorpora el índice t a la notación que se emplea de manera que con $S_i(t)$ se indica el conjunto de patrones asociados al agrupamiento S_i en la iteración t y mediante $Z_i(t)$ se indica el valor de su centro en esa iteración.

El algoritmo de las k -medias con las variables y pasos descritos anteriormente se muestra a continuación,

Algoritmo de las K-medias

Entradas:

X conjunto de N patrones $\{X_1, \dots, X_N\}$.

$k \in N$ número de agrupamientos.

Salidas:

S_1, S_2, \dots, S_k k conjuntos de patrones (agrupamientos).

Z_1, Z_2, \dots, Z_k Los centros de k agrupamientos.

1. Inicialización.

$t \leftarrow 0$

Seleccionar $Z_i(t), i = 1, 2, \dots, k$ {Inicializar los k centros}

2. Asignación y actualización de centros.

$t \leftarrow t + 1$

Repetir para $X = X_1, X_2, \dots, X_N$

$m \leftarrow \text{Grupo más cercano}(X)$ {Asignar cada X }

$S_m(t) \leftarrow S_m(t-1) \cup \{X\}$ {Al grupo más cercano}

Fin-paro // para $X = X_1, X_2, \dots, X_N$

Repetir para $i = 1, 2, \dots, k$

$Z_i(t) \leftarrow \text{Recalcular centro}(i)$ {Recalcular los centros}

Fin-paro // para $i = 1, 2, \dots, k$

3. Convergencia.

Si $Z_i(t) \leftarrow Z_i(t-1)$, para $i = 1, 2, \dots, k$

Terminar

Si-no {Algún $Z_i(t) \neq Z_i(t-1)$ }

Ir al paso 2.

Fin-paro // Si $Z_i(t) = Z_i(t-1)$, $i = 1, 2, \dots, k$

El algoritmo es muy sencillo y eficiente ya que todos los cálculos resultan muy sencillos. Hay que destacar que el resultado final depende del valor de k , aunque el mayor problema está relacionado con la inicialización de los centros.

Aunque los centros iniciales pueden seleccionarse aleatoriamente, si éstos se seleccionan de manera que se dispersen uniformemente sobre el espacio de

representación, es más fácil que el resultado final sea mejor, además de acelerar la convergencia.

A continuación se presenta un ejemplo de la utilización del algoritmo de k -medias.

En la Figura A1(a) se muestra un conjunto de patrones sobre el que se va a aplicar el algoritmo de las k -medias con $k = 2$.

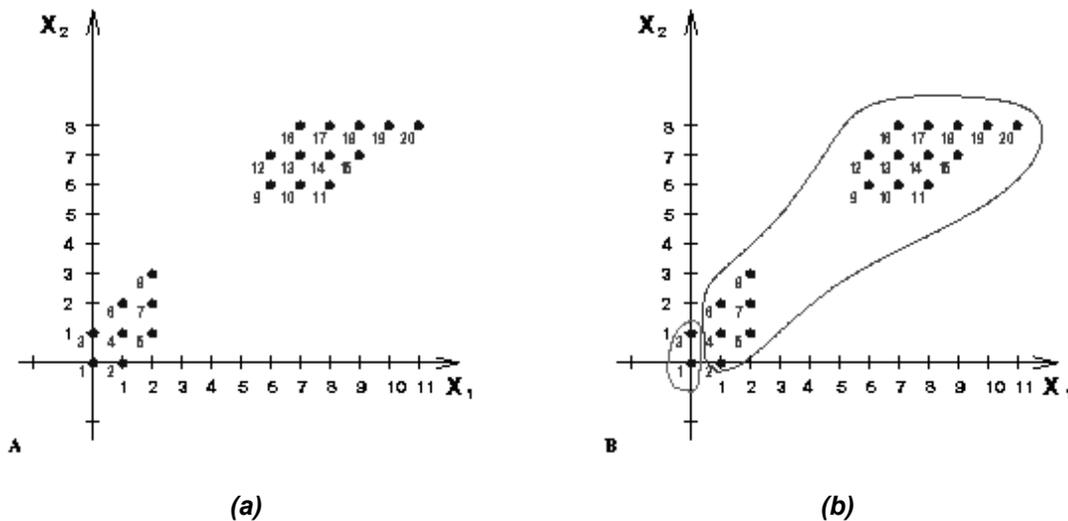


Figura A1. (a) Situación inicial, (b) Resultado de la primera asignación.

Paso 1. Inicialización

Suponga que los centros se inician por el orden en que están los patrones en X de la siguiente manera:

$$S_1(0) = \{X_1\} \quad Z_1(0) = (0, 0)$$

$$S_2(0) = \{X_2\} \quad Z_2(0) = (1, 0)$$

Paso 2. Asignación y actualización de centros

Se asigna en base a la menor distancia entre $(X, Z_1(0))$ y $(X, Z_2(0))$ y finalmente se calcula $Z_1(1)$ y $Z_2(1)$ (ver Figura A1(b)):

$$S_1(1) = \{X_1, X_3\} \quad Z_1(1) = (0, 0.5)$$

$$S_2(1) = \{X_2, X_4, X_5, \dots, X_{20}\} \quad Z_2(1) = (5.8, 5.3)$$

Paso 3. Convergencia

Como $Z_1(1) \neq Z_1(0)$ y $Z_2(1) \neq Z_2(0)$ se repite el paso 2.

Paso 2. Asignación y actualización de centros (2)

Se asigna en base a la menor distancia entre $(X, Z_1(1))$ y $(X, Z_2(1))$ y finalmente calculamos $Z_1(2)$ y $Z_2(2)$ (ver Figura A2(a)):

$$\begin{aligned} S_1(2) &= \{X_1, X_2, \dots, X_8\} & Z_1(2) &= (1.1, 1.3) \\ S_2(2) &= \{X_9, X_{10}, \dots, X_{20}\} & Z_2(2) &= (8.0, 7.2) \end{aligned}$$

Paso 3. Convergencia (2)

Como $Z_1(2) \neq Z_1(1)$ y $Z_2(2) \neq Z_2(1)$ se vuelve al paso 2.

Paso 2. Asignación y actualización de centros (3)

Si asignamos en base a la menor distancia entre $(X, Z_1(2))$ y $(X, Z_2(2))$ y finalmente calculamos $Z_1(3)$ y $Z_2(3)$ (ver Figura A2(b)):

$$\begin{aligned} S_1(3) &= \{X_1, X_2, \dots, X_8\} & Z_1(3) &= (1.1, 1.3) \\ S_2(3) &= \{X_9, X_{10}, \dots, X_{20}\} & Z_2(3) &= (8.0, 7.2) \end{aligned}$$

Paso 3. Convergencia (3)

Finalmente, como $Z_1(3) = Z_1(2)$ y $Z_2(3) = Z_2(2)$ se considera que la partición obtenida es estable y se termina. La partición final es la mostrada en la Figura A2 (b).

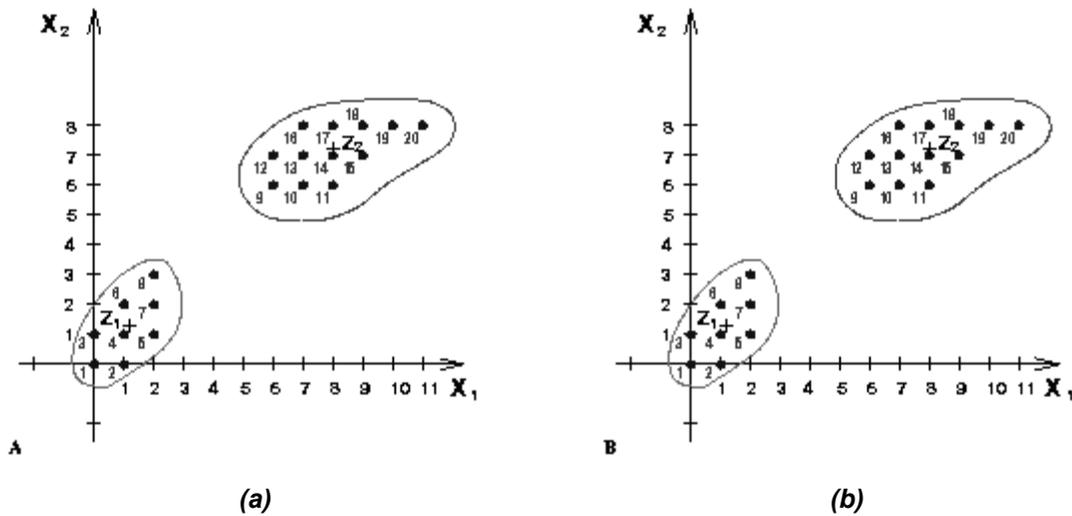


Figura A2. (a) Segunda asignación. (b) Tercera y última asignación.

REFERENCIAS

- [1] http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial_html/kmeans.html
- [2] Pedro Isasi Viñuela, Inés M. Galván León, “Redes Neuronales Artificiales, un enfoque práctico” Pearson-Prentice Hall, 2004. Páginas 206-208.
- [3] S. Haykin, “Neural Networks, a comprehensive foundation”, 2nd Edition, Prentice Hall. 1999. Páginas 256-293.

GLOSARIO

Axón.- Parte de las neuronas que conduce un impulso eléctrico desde el cuerpo de una neurona hasta otra neurona.

Biopsia.- Examen de un trozo de tejido perteneciente a un ser vivo, como el tejido interno del intestino, que se remueve para completar un diagnóstico.

Carcinoma.- forma de cáncer con origen en células de estirpe epitelial (tejido de recubrimiento formado por una fina capa de células) o glandular (tejido que produce o libera una o mas sustancias para ser usadas por el organismo). Los carcinomas constituyen el tipo más común de cáncer. Lugares comunes de carcinomas son la piel, la boca, el pulmón, los senos, el estómago, el colon y el útero.

Dendritas.- ramificaciones de las neuronas que pueden recibir comunicación de los axones.

Densitómetro.- aparato para medir la densidad óptica de un material, como por ejemplo el negativo de una foto.

Despolarizar.- disminución del potencial de la membrana dendrítica.

Displasia.- Alteración precancerosa, en diferentes grados de gravedad, que puede regresar o evolucionar. También se utiliza éste término para describir una malformación congénita.

Distribución normal.- También conocida como distribución de Gauss o distribución gaussiana, es la distribución de probabilidad que con más frecuencia aparece en estadística y teoría de probabilidades. Esto se debe a dos razones fundamentalmente: (1) Su función de densidad es simétrica y con forma de campana, lo que favorece su aplicación como modelo a gran número de variables estadísticas; (2) Es, además, límite de otras distribuciones y aparece relacionada con multitud de resultados ligados a la teoría de las probabilidades gracias a sus propiedades matemáticas.

Espacio euclídeo.- El espacio euclídeo es el espacio matemático n -dimensional usual, una generalización de los espacios de 2 (plano euclídeo) y 3 dimensiones

estudiados por Euclides. Formalmente, para cada número entero no negativo n , el espacio euclídeo n -dimensional es el conjunto \mathbb{R}^n .

Estrógenos.- Hormonas sexuales.

Estructura de datos.- Forma de organizar un conjunto de datos elementales (un dato elemental es la mínima información que se tiene en un sistema) con el objetivo de facilitar la manipulación de estos datos como un todo o individualmente.

Falso negativo.- resultado de una prueba que implica que no existe una condición cuando en realidad sí existe.

Falso positivo.- resultado de una prueba que implica que existe una condición cuando en realidad no existe

Ganglios linfáticos.- Pequeñas glándulas con forma de frijol que se encuentran a lo largo de todo el cuerpo y que ayudan a eliminar bacterias, virus y células cancerosas.

Inteligencia artificial.- rama de la Informática que pretende desarrollar programas en los que el ordenador desarrolle conductas típicas de los seres inteligentes.

In situ.- Término que se refiere a que un cáncer no ha pasado la membrana basal (membrana no celular que separa distintos tipos de tejidos).

Metástasis.- Extensión de un cáncer a un órgano del cuerpo distinto al órgano en el que se originó. Esto puede ser mediante el sistema linfático o el torrente sanguíneo.

Microdensitómetro.- Densitómetro extremadamente sensible usado para detectar líneas espectrales demasiado borrosas para ser vistas por el ojo humano.

Neurotransmisores.- Sustancias, productos o compuestos que transmiten los impulsos nerviosos en las sinapsis neuronales.

Progesterona.- hormona femenina que se produce fundamentalmente en el ovario y la placenta.

Psicoanálisis.- Es una disciplina compuesta de un conjunto de teorías creadas para tratar enfermedades mentales. El psicoanálisis se basa en la revelación del inconsciente.

Resonancia magnética.- En Medicina, técnica de diagnóstico por imagen, basada en el fenómeno físico de la resonancia, por la cual se obtienen imágenes internas del organismo.

Retroareolar.- Término que se refiere a la parte del seno sobre la que se encuentra el pezón.

Sinapsis.- Las sinapsis son las uniones que se producen entre el axón de una neurona y las dendritas o cuerpo celular de otra neurona. La actividad de una influye en las neuronas con las que está conectada. Puede ser química o eléctrica, y excitadora o inhibidora.

REFERENCIAS

[1] www.biomed.net/biomed/glosario.htm

[2] <http://www.thefreedictionary.com>

COLECCIÓN DE IMÁGENES DE MAMOGRAFÍA

El acceso a muestras médicas puede ser una tarea difícil debido a cuestiones de privacidad o incluso por cuestiones de papeleo o burocráticas. En cambio, mediante el uso de internet se puede tener acceso a algunas imágenes, útiles para cuestiones de pruebas y experimentación, de manera más sencilla.

Las imágenes utilizadas en este trabajo se obtuvieron de tres fuentes de internet, y de todas las mamografías se tiene su diagnóstico correspondiente:

- De la primera fuente, que es una galería de imágenes de mamografías de la “Clínica Virtual Ginecológica” de Buenos Aires, Argentina, se utilizaron dos imágenes que mostraban microcalcificaciones cancerígenas [1].
- De la segunda fuente, que es la página de internet del Hospital General “Obispo Polanco” de Teruel, España, se obtuvieron seis imágenes que mostraban diversos tumores cancerosos [2].
- De la tercera fuente se utilizaron 157 imágenes que se encuentran divididas en tres grandes grupos: normales, benignas y malignas. Esta base de datos está muy detallada, y fue obtenida de la Sociedad de Análisis de Imágenes de Mamografía (MIAS por sus siglas en Inglés) [3]. Existen trabajos relacionados con el tema de análisis digital de mamografías usan esta colección de imágenes como referencia.

SOCIEDAD DE ANÁLISIS DE IMÁGENES DE MAMOGRAFÍA (MIAS)

Las imágenes en esta base de datos fueron escaneadas con un microdensitómetro Joyce-Loebl SCANDIG-3, el cual tiene una respuesta lineal en el rango óptico de 0-3.2. Cada píxel tiene una profundidad de 8 bits a una resolución de $200\mu\text{m} \times 200\mu\text{m}$ ($50\mu\text{m} \times 50\mu\text{m}$ en la base de datos original), y cada imagen es de 1024×1024 píxeles.

Información de la base de datos de MIAS

La lista de las imágenes de mamografías usadas consta originalmente de 7 columnas, aunque para el propósito de este trabajo sólo se tomaron en cuenta las primeras 4. Para mayor detalle sobre la base de datos se puede consultar la referencia [3].

Primera columna: nombre de referencia de la imagen.

Segunda columna: tejido de fondo:

- F Grueso o grasoso
- G Grueso-granular
- D Denso-granular

Tercera columna: Clase de anomalía presente:

- CALC Calcificación
- CIRC Masa bien definida/circunscrita
- SPIC Masas de contorno irregular⁴
- MISC Otras masas definidas (malas)
- ARCH Distorsión de arquitectura
- ASYM Asimetría
- NORM Normal

Cuarta columna: severidad de la anomalía.

- B Benigna
- M Maligna

⁴ SPIC se refiere a la palabra "spiculated", de la cual no se encontró su traducción. Spiculated es un término usado en el área del cáncer de mama para referirse a masas con contorno irregular.

Mamografías usadas en la fase de entrenamiento para determinar parámetros:

mdb001	G	CIRC	B
mdb002	G	CIRC	B
mdb003	D	NORM	
mdb007	G	NORM	
mdb010	F	CIRC	B
mdb012	F	CIRC	B
mdb013	G	MISC	B
mdb014	G	NORM	
mdb015	G	CIRC	B
mdb016	G	NORM	
mdb017	G	CIRC	B
mdb018	G	NORM	
mdb020	G	NORM	
mdb022	G	NORM	
mdb023	G	CIRC	M
mdb024	G	NORM	
mdb028	F	CIRC	M
mdb058	D	MISC	M
mdb072	G	ASYM	M
mdb075	F	ASYM	M
mdb090	G	ASYM	M
mdb095	F	ASYM	M
mdb102	D	ASYM	M
mdb164	D	NORM	
mdb212	G	CALC	B
mdb213	G	CALC	M
mdb214	G	CALC	B
mdb216	D	CALC	M
mdb218	G	CALC	B
mdb219	G	CALC	B
mdb209	G	CALC	M
mdb211	G	CALC	M

Total de mamografías: 32

Mamografías usadas para probar el sistema:

mdb004	D	NORM	
mdb005	F	CIRC	B
mdb006	F	NORM	
mdb008	G	NORM	
mdb009	F	NORM	
mdb011	F	NORM	
mdb019	G	CIRC	B
mdb021	G	CIRC	B
mdb025	F	CIRC	B
mdb026	F	NORM	
mdb027	F	NORM	
mdb029	G	NORM	
mdb030	G	MISC	B
mdb031	G	NORM	
mdb032	G	MISC	B
mdb033	D	NORM	
mdb034	D	NORM	
mdb035	D	NORM	
mdb036	D	NORM	
mdb037	D	NORM	
mdb038	D	NORM	
mdb039	D	NORM	
mdb040	D	NORM	
mdb041	G	NORM	
mdb042	G	NORM	
mdb043	G	NORM	
mdb044	G	NORM	
mdb045	G	NORM	
mdb046	G	NORM	
mdb047	G	NORM	
mdb048	G	NORM	
mdb049	G	NORM	
mdb050	G	NORM	
mdb051	G	NORM	
mdb052	G	NORM	
mdb053	D	NORM	
mdb054	D	NORM	
mdb055	G	NORM	
mdb056	G	NORM	
mdb057	D	NORM	
mdb059	F	CIRC	B
mdb060	F	NORM	
mdb061	D	NORM	
mdb063	D	MISC	B
mdb069	F	CIRC	B
mdb080	F	CIRC	B
mdb081	G	ASYM	B
mdb083	G	ASYM	B
mdb091	F	CIRC	B
mdb092	F	ASYM	M
mdb097	F	ASYM	B
mdb099	D	ASYM	B

mdb104	D	ASYM	B
mdb105	D	ASYM	M
mdb107	D	ASYM	B
mdb110	D	ASYM	M
mdb111	D	ASYM	M
mdb115	G	ARCH	M
mdb117	G	ARCH	M
mdb120	G	ARCH	M
mdb121	G	ARCH	B
mdb124	G	ARCH	M
mdb125	D	ARCH	M
mdb126	D	ARCH	B
mdb127	G	ARCH	B
mdb130	D	ARCH	M
mdb134	F	MISC	M
mdb141	F	CIRC	M
mdb144	F	MISC	M
mdb145	D	SPIC	B
mdb148	F	SPIC	M
mdb150	F	ARCH	B
mdb152	F	ARCH	B
mdb155	F	ARCH	M
mdb158	F	ARCH	M
mdb160	F	ARCH	B
mdb163	D	ARCH	B
mdb165	D	ARCH	B
mdb167	F	ARCH	B
mdb170	D	ARCH	M
mdb171	D	ARCH	M
mdb175	G	SPIC	B
mdb178	G	SPIC	M
mdb179	D	SPIC	M
mdb181	G	SPIC	M
mdb184	F	SPIC	M
mdb186	G	SPIC	M
mdb188	G	SPIC	B
mdb190	G	SPIC	B
mdb191	G	SPIC	B
mdb193	D	SPIC	B
mdb198	D	SPIC	B
mdb199	D	SPIC	B
mdb202	D	SPIC	M
mdb204	F	SPIC	B
mdb206	F	SPIC	M
mdb222	D	CALC	B
mdb223	D	CALC	B
mdb223	D	CALC	B
mdb226	D	CALC	B
mdb227	G	CALC	B
mdb231	F	CALC	M
mdb233	G	CALC	M
mdb236	D	CALC	B
mdb238	F	CALC	M
mdb240	D	CALC	B

mdb241	D	CALC	M
mdb244	D	CIRC	B
mdb245	F	CALC	M
mdb248	F	CALC	B
mdb249	D	CALC	M
mdb249	D	CALC	M
mdb252	F	CALC	B
mdb253	D	CALC	M
mdb256	F	CALC	M
mdb270	G	CIRC	M
mdb271	F	MISC	M
mdb274	F	MISC	M
mdb290	D	CIRC	B
mdb312	F	MISC	B
mdb314	F	MISC	B
mdb316	D	NORM	
mdb317	D	NORM	
mdb318	D	NORM	
mdb319	D	NORM	

Total de mamografías: 125

REFERENCIAS

- [1] <http://members.tripod.com/~gineco>
- [2] www.opolanco.es
- [3] <http://www.wiau.man.ac.uk/services/MIAS/MIAScom.html>


```

% LECTURA DE LA IMAGEN
im00=imread('mias\MDB028.jpg');
im01=uint8(im00);
figure;
imshow(im01);
colormap(gray);
title('IMAGEN ORIGINAL');

% DILATACIÓN
el_est1=strel('diamond',1);
imdilata1=imdilate(im01,el_est1);
figure;
subplot(2,2,1);
imshow(imdilata1);
colormap(gray);
title('IMAGEN OBTENIDA CON LA DILATACIÓN');

% RELLENO DE HUECOS
imrell_h = imfill(imdilata1,8,'holes');
subplot(2,2,2);
imshow(imrell_h);
colormap(gray);
title('IMAGEN EN LA QUE SE LLENAN HUECOS');

% IMAGEN EN LA QUE LOS PUNTOS FUERA DEL BORDE SE ELIMINAN
im_sinb= imclearborder(imrell_h,8);
subplot(2,2,3);
imshow(im_sinb);
colormap(gray);
title('IMAGEN EN LA QUE LOS PUNTOS FUERA DE LOS BORDES SE ELIMINAN');

% DETECCIÓN DE OBJETO USANDO EROSIÓN Y CÁLCULO DE UMBRAL
imdeto = imerode(im_sinb,el_est1);
imdeto_ob= imerode(imdeto_ob,el_est1);
umbral=(max(max(imdeto_ob)))*0.2;
[o,p]=size(imdeto_ob);
for i=1:o,
    for j=1:p,
        if(imdeto_ob(i,j)>=umbral)
            imdeto_ob(i,j);
        else
            imdeto_ob(i,j)=0;
        end
    end
end
subplot(2,2,4);
imshow(imdeto_ob);
colormap(gray);
title('IMAGEN SEGMENTADA');

% MARCA DE OBJETO DETECTADO EN LA MAMOGRAFÍA ORIGINAL
im_objmarc1= bwperim(imdeto_ob,8);

% MARCACIÓN DEL OBJETO DETECTADO EN COLOR BLANCO
im_obor = imfill(im_objmarc1,8,'holes');
im_obor = bwareaopen(im_obor,40);
figure;
subplot(2,1,1);
imshow(im_obor);
colormap(gray);
title('MARCACIÓN DEL OBJETO DETECTADO');

% ÁREA, PERÍMETRO Y VALOR DE LOS PÍXELES DEL OBJETO DETECTADO

```

```

npix_cal=1;
perim_cal=0;
for i=1:o
    for j=1:p
        if im_obor(i,j)==1,
            valor1(npix_cal)=im01(i,j);
            cx_cal(npix_cal)=i;
            cy_cal(npix_cal)=j;
            npix_cal=npix_cal+1;
        end
        if im_objmarc1(i,j)==1,
            perim_cal=perim_cal+1;
        end
    end
end
npix_cal=npix_cal-1;

% SEGMENTACIÓN Y MARCA DEL SENO
im02=uint8(zeros(size(im01)));
for i=1:o,
    for j=1:p,
        if(im01(i,j)>=50)
            im02(i,j)=255;
        end
    end
end
im02 = imfill(im02,8,'holes');
im02 = bwareaopen(im02,100);
el_est2=strel('disk',1,8);
imdilata2=imdilate(im02,el_est2);
im02=imdilate(imdilata2,el_est2);
subplot(2,1,2);
imshow(im02);
colormap(gray);
title('RECONOCIMIENTO DEL SENO');
im_objmarc2= bwperim(im02,8);

% ÁREA, PERÍMETRO Y VALOR DE LOS PÍXELES DEL SENO
pix_mam=im02-im_obor;
npix_mam=1;
perim_mam=0;
for i=1:o
    for j=1:p
        if pix_mam(i,j)==1,
            valor2(npix_mam)=im01(i,j);
            cx_mam(npix_mam)=i;
            cy_mam(npix_mam)=j;
            npix_mam=npix_mam+1;
        end
        if im_objmarc2(i,j)==1,
            perim_mam=perim_mam+1;
        end
    end
end
npix_mam=npix_mam-1;
ima=uint8(im_objmarc1)+uint8(im_objmarc2);
ima=logical(ima);
obj_det=im01;
obj_det(ima)=255;
figure;
imshow(obj_det);
colormap(gray);
title('IMAGEN SEGMENTADA');

```

```
% SE CREA UN VECTOR LLAMADO datos, EN EL CUAL SE VAN A GUARDAR VALORES
% ESTADÍSTICOS DE LA IMAGEN QUE SE PROCESÓ
datos(1)=npix_cal;
datos(2)=npix_mam;
datos(3)=perim_cal;
datos(4)=perim_mam;
datos(5)=mean(valor1);
datos(6)=mean(valor2);
datos(7)=median(valor1);
datos(8)=median(valor2);
datos(9)=sum(valor1);
datos(10)=sum(valor2);
datos(11)=max(valor1);
datos(12)=max(valor2);
datos(13)=min(valor1);
datos(14)=min(valor2);
datos(15)=std(valor1);
datos(16)=std(valor2);

% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %

% EL VECTOR OBTENIDO SE GUARDA EN UNA BASE DE DATOS
xlswrite('valores.xls',datos','...','...');
```



```
dvma=[dato1...dato_n];  
[in_dvm,c_dvm]=kmeans(dvma',2);  
  
rmam=[dato1...dato_n];  
[in_rm,c_rm]=kmeans(rmam',2);  
  
pobj=[dato1...dato_n];  
[in_pob,c_pob]=kmeans(pobj',2);  
  
pmam=[dato1...dato_n];  
[in_pob,c_pob]=kmeans(pmam',2);  
  
dobj=[ dato1...dato_n];  
[inmedob,cmedob]=kmeans(dobj',2)  
  
robj=[ dato1...dato_n];  
[in_cmp,c_cmp]=kmeans(robj',2);  
  
cont=[ dato1...dato_n];  
[in_cmp,c_cmp]=kmeans(cont',2);  
  
dvma=[ dato1...dato_n];  
[in_dvm,c_dvm]=kmeans(dvma',2);
```

CLASIFICADOR

```

% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %
close all;
clear all;
clc;

% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %

% JOSÉ AUGUSTO MORENO ESCOBAR
% PROGRAMA PARA CLASIFICAR IMÁGENES
% DE MAMOGRAFÍA

% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %

% VARIABLES
% centros      CENTROS DE CADA FUNCIÓN RADIAL OBTENIDOS PREVIAMENTE
% norm         VECTOR EN DONDE SE GUARDAN LOS VALORES DE
%              NORMALIZACIÓN
% bias         VECTOR QUE CONTIENE VALORES DE AJUSTE
% pondera      VALORES POR LOS QUE SE MULTIPLICA LA SALIDA DE CADA
%              FUNCIÓN RADIAL
% umbrales     VECTOR QUE CONTIENE EL UMBRAL PARA CADA
%              CARACTERÍSTICA INTRODUCIDA AL CLASIFICADOR
% imagen       VARIABLE USADA PARA LEER LAS CARACTERÍSTICAS DE LA
%              IMAGEN QUE SE VA A ANALIZAR
% dist         VARIABLE PARA CALCULAR LA DISTANCIA DE CADA DATO CON
%              SU RESPECTIVA FUNCIÓN RADIAL
% alog         ANTILOGARITMO BASE 10 DE LAS DISTANCIAS CALCULADAS.
%              ESTO SE HACE PARA PODER "ESTIRAR" LOS DATOS
% alog_bias    RESULTADO DE MULTIPLICAR LAS VARIABLES alog Y bias
% fun_rad      VECTOR EN EL QUE SE ALMACENAN LOS RESULTADOS QUE
%              ENTREGA CADA FUNCIÓN RADIAL
% fun_radp     RESULTADO DE MULTIPLICAR LAS VARIABLES fun_rad Y
%              pondera
% sal1         VARIABLE EN LA QUE SE GUARDA EL VALOR OBTENIDO AL USAR
%              UNA FUNCIÓN HARDLIMS DE LA DIFERENCIA ENTRE LAS
%              VARIABLES fun_rad Y umbrales
% sal2         VARIABLE PARA OBTENER LA SUMA DE LOS VALORES DE sum1
% i,j         VARIABLES DE CONTEO
% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %
close all;
clear all;
clc

centros=[.....];
norm=[10000 10 100 1 1000 1000 100 1000];
bias=[0.85 1.15 1.195 7.5 0.98 1.2005 1.05 0.95];
pondera=[1000 1000 1000 10000 1000 1000 1000 1000];
umbrales=[535 300 400 140 500 400 270 505];

% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %
imagen=xlsread('f:\dmc_rna\pruebas y
graficas\8_características\mdatabase8.xls','...','...');
for i=1:8
    d_imagen(i)=imagen(i)/norm(i);
end
for i=1:8
    dist(i)=sqrt((centros(i)-d_imagen(i)).^2);
end
for i=1:8
    alog(i)=10^dist(i);

```

```
end
alog_bias=alog.*bias';
for i=1:8
    fun_rad(i)=1/(1+(alog_bias(i)*alog_bias(i)));
end
fun_radp=fun_rad.*pondera';
sal1(1)=umbrales(1)-fun_radp(1);
sal1(2)=fun_radp(2)-umbrales(2);
sal1(3)=fun_radp(3)-umbrales(3);
sal1(4)=umbrales(4)-fun_radp(4);
sal1(5)=fun_radp(5)-umbrales(5);
sal1(6)=fun_radp(6)-umbrales(6);
sal1(7)=fun_radp(7)-umbrales(7);
sal1(8)=umbrales(8)-fun_radp(8);
for i=1:8
    if sal1(i)>=0
        sal2(i)=1;
    else
        sal2(i)=-1;
    end
end
if sal1(i)>=0
    sal2(i)=1;
else
    sal2(i)=-1;
end
end
salida=sum(sal2)
xlswrite('f:\dmc_rna\pruebas y
graficas\8_caracteristicas\resultado8.xls',salida,'...', '...');
```

PUBLICACIONES Y CONGRESOS



Constancia de participación en la XVI REUNIÓN DE COMUNICACIONES, COMPUTACIÓN, ELECTRÓNICA Y EXPOSICIÓN INDUSTRIAL ROC&C 2005, con la ponencia “**LA FUNCIÓN RADIAL BÁSICA COMO UN MÉTODO PARA LA DETECCIÓN DE MICROCALCIFICACIONES EN IMÁGENES DE MAMOGRAFÍA**”. IEEE Sección México. Hotel Hyatt. Acapulco, Gro.



Constancia de participación en el III Encuentro PARTICIPACIÓN DE LA MUJER EN LA CIENCIA con la ponencia “**DETECCIÓN DE MICROCALCIFICACIONES EN IMÁGENES DE MAMOGRAFÍA USANDO REDES NEURONALES**”. ISBN 968-9241-02-8. Centro de Investigaciones en Óptica (CIO). León, Gto.



INSTITUTO POLITÉCNICO NACIONAL
ESCUELA SUPERIOR DE CÓMPUTO



1er **CISCE2006** CONGRESO INTERNACIONAL DE SISTEMAS COMPUTACIONALES Y ELECTRÓNICOS
DEL 23 AL 25 DE AGOSTO DE 2006, CIUDAD DE MÉXICO.

Otorga la presente

CONSTANCIA

A José Augusto Moreno-Escobar

Por su participación como Autor de la Ponencia H005
“Segmentación de Microcalcificaciones en Imágenes Médicas”
en el 1er Congreso Internacional de Sistemas Computacionales y Electrónicos 2006
México, D. F. a 25 de agosto de 2006
“LA TÉCNICA AL SERVICIO DE LA PATRIA”



Dr. Raúl Acosta Bermejo
Subdirector Académico



M. en C. © Apolinar Francisco Cruz Lázaro
Director



M. en C. Rodolfo Romero Herrera
Presidente del CISCE 2006

Constancia de participación en el 1^{ER} CONGRESO INTERNACIONAL DE SISTEMAS COMPUTACIONALES Y ELECTRÓNICOS CISCE 2006 con la ponencia “**SEGMENTACIÓN DE MICROCALCIFICACIONES EN IMÁGENES MÉDICAS**”. ESCOM, IPN. Hotel Torres Lindavista, México, D.F.



Constancia de participación en el ENCuentro PIFI 2006 con la ponencia **“USO DE REDES NEURONALES Y PROCESAMIENTO MORFOLÓGICO PARA DETECTAR CÁNCER”**. ESIME Allende, IPN. México, D.F.



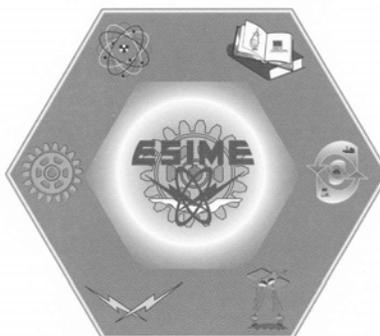
INSTITUTO POLITÉCNICO NACIONAL
ESCUELA SUPERIOR DE INGENIERÍA MECÁNICA Y ELÉCTRICA



9º
CONGRESO NACIONAL
DE INGENIERÍA ELECTROMECÁNICA Y DE SISTEMAS
del 13 al 17 de noviembre de 2006

otorga el presente

DIPLOMA



A:

JOSÉ AUGUSTO MORENO ESCOBAR

“POR SU PARTICIPACIÓN EN LA PONENCIA”

“ANÁLISIS DE MAMOGRAFÍAS USANDO TÉCNICAS DE
SEGMENTACIÓN DE IMÁGENES Y ANÁLISIS ESTADÍSTICO”

México, D.F., a 13 de noviembre de 2006

DR. JAIME ROBLES GARCÍA
Jefe de la Sección de Estudios de Posgrado
e Investigación de la ESIME

70

Aniversario
INSTITUTO POLITÉCNICO NACIONAL
1936 • 2006

M. EN C. JESÚS REYES GARCÍA
Director de la ESIME Unidad Zacateco

Constancia de participación en el 9º CONGRESO NACIONAL DE INGENIERÍA ELECTROMECÁNICA Y DE SISTEMAS con la ponencia “**ANÁLISIS DE MAMOGRAFÍAS USANDO TÉCNICAS DE SEGMENTACIÓN DE IMÁGENES Y ANÁLISIS ESTADÍSTICO**”. ISBN 970-36-0355-6. Unidad Politécnica para el Desarrollo y la Competitividad Empresarial, IPN. México, D.F.



Constancia de participación en el congreso ELECTRONIC IMAGING 2007 con la ponencia **“RANK M TYPE RADIAL BASIS FUNCTION NETWORK FOR MEDICAL IMAGE PROCESSING APPLICATIONS”**. Proc. SPIE 6497, 649715 (2007). San Jose Convention Center, California, EUA.



Constancia de participación en el 8º Congreso de Computación CORE 2007 con la ponencia **“MAMMOGRAPHIC IMAGES ANALYSIS BY USE THE RMRBF NEURAL NETWORK”**. CIC, IPN. México, D.F.

El artículo de esta ponencia fue publicado en la revista **“ADVANCES IN COMPUTER SCIENCE AND ENGINEERING”**. RESEARCH IN COMPUTING SCIENCE, Vol. 27. Mayo de 2007. ISSN: 1870-4069.



THE SIXTH INTERNATIONAL KHARKOV SYMPOSIUM ON
PHYSICS AND ENGINEERING OF MICROWAVES,
MILLIMETER AND SUBMILLIMETER WAVES (MSMW'07) AND
WORKSHOP ON TERAHERTZ TECHNOLOGY (TERATECH'07)
Kharkov, Ukraine, June 25-30, 2007



18 May, 2007

National Polytechnic Institute of Mexico
Mechanical and Electrical
Engineering Higher School
Av. IPN s/n, U.P.A.L.M. SEPI-ESIME,
Edif. Z, Acceso 3, Tercer Piso, SEPI Electronica,
Col. Lindavista, 07738,
Mexico, D. F., Mexico

Dear Dr. Francisco J. Gallegos-Funes,

You are kindly invited to participate in the 6-th International Kharkov Symposium on Physics and Engineering of Microwaves, Millimeter and Sub-Millimeter Waves (MSMW'07) to be held in Kharkov National University, Ukraine on June 25 - 30, 2007, for presentation of your papers:

Francisco J. Gallegos-Funes, José L. Varela-Benítez, Volodymyr I. Ponomaryov "Real-time implementation of RM-filters for noise suppression in 3d ultrasound imaging";

Francisco J. Gallegos-Funes, José A. Moreno-Escobar, Volodymyr I. Ponomaryov "Mammographic image analysis by use the rank m-type radial basis function network"

as a poster report in the Session XI-11, XI-12 (R-functions, atomic functions, wavelets, fractals).

Please, note that each poster presenter will be provided with a vertical surface to mount their poster presentation. The area available for the poster is limited to a rectangle 85 cm tall by 65 cm wide.

You may use this letter for application for Ukrainian visa.

Note that we shall take care of booking your accommodation and arranging your local transportation in Ukraine.

Looking forward to seeing you in Kharkov in June

Sincerely yours

Prof. Vladimir M. Yakovenko
MSMW'07 Chairman

Constancia de aceptación del artículo **“MAMMOGRAPHIC IMAGE ANALYSIS BY USE THE RANK M-TYPE RADIAL BASIS FUNCTION NETWORK”** para su exposición en THE SIXTH INTERNATIONAL KHARKOV SYMPOSIUM ON PHYSICS AND ENGINEERING OF MICROWAVES, MILLIMETER AND SUBMILLIMETER WAVES (MSMW'07) AND WORKSHOP ON TERAHERTZ TECHNOLOGY (TERATECH'07), que se llevará a cabo en Kharkov, Ucrania, del 25 al 30 de Junio de 2007.