



**UNIVERSIDAD DE SANTIAGO DE CHILE  
FACULTAD DE INGENIERÍA**

**SEGMENTACIÓN DE FALLAS EN SOLDADURAS  
UTILIZANDO TÉCNICAS DE PROCESAMIENTO  
DIGITAL DE IMÁGENES**

**MIGUEL CARRASCO ZAMBRANO  
2003**



**UNIVERSIDAD DE SANTIAGO DE CHILE  
FACULTAD DE INGENIERÍA**

**SEGMENTACIÓN DE FALLAS EN SOLDADURAS  
UTILIZANDO TÉCNICAS DE PROCESAMIENTO  
DIGITAL DE IMÁGENES**

**MIGUEL CARRASCO ZAMBRANO**

TESIS DE GRADO PRESENTADO EN CONFORMIDAD A LOS REQUISITOS PARA OBTENER EL  
GRADO DE MAGÍSTER EN INGENIERÍA INFORMÁTICA

Comisión integrada por los profesores:

Profesor Guía: Ph.D. Domingo Mery Q.  
Comisión: Ph.D. Danilo Bassi A.  
M.Sc. Fernando Contreras B.  
Ph.D. Álvaro Soto A.

**SANTIAGO DE CHILE  
2003**

## AGRADECIMIENTOS

*El trabajo realizado es el fin de un proceso que comenzó en 1997. En aquellos días era impensable ver el momento en que llegaría el término de esta carrera. Mucho trabajo, esfuerzo y ganas de superarse ha permitido terminar con éxito este largo proceso. Sin embargo, no hubiese sido posible sin el apoyo de: Marco, Roberto, José Luis, Edson, Francisco, Melissa, Paulina, Gonzalo, Nicolás, Daniela y Pablo; un excelente grupo amigos, estudio y trabajo con quienes tuve la suerte de compartir buenos y malos momentos, pero al final terminamos con éxito el desafío de superarnos nosotros mismos.*

*Quisiera agradecer a mi profesor guía, Domingo Mery por la gran cantidad de consultas, reuniones, correos y acotaciones que tuvo que sobrellevar durante todo el tiempo en que desarrolle mi tesis. Muchas gracias por el apoyo, los consejos y la motivación brindada.*

*El apoyo de mi familia ha sido fundamental, especialmente de mis padres. A mi padre agradezco el tiempo y el trabajo que dedicó para realizarme una gran cantidad de acotaciones y correcciones. A mi madre el constante apoyo y motivación brindada durante todo el tiempo que desarrollé este trabajo. A pesar de difíciles momentos que he tenido en mi vida, ellos siguieron con mucho optimismo apoyándome en todo momento. A mis hermanas agradezco todo el apoyo dado y aunque estén repartidas a lo largo de Chile, siempre las llevo en mi corazón.*

*No puedo dejar de dar las gracias a amigos como: Ricardo, Felipe, Marcelo, Álvaro y Jorge; grandes amigos del colegio. En momentos difíciles ellos me brindaron muchos consejos. Espero seguir contando siempre con ellos.*

*Muchas gracias a todos*

*Dedicado a  
Mis padres y hermanas*

## RESUMEN

Esta tesis tiene como objetivo desarrollar un filtro de imágenes digitales para segmentar fallas en soldaduras, utilizando técnicas de procesamiento digital, dentro de las cuales se encuentran los filtros de atenuación del ruido, operadores matemáticos morfológicos, técnicas de detección de bordes como el filtro de Canny, la transformada de Watershed y la transformada de la distancia.

El estudio contempla el análisis, la comparación y cómo los filtros utilizados operan en combinación para mejorar el proceso de segmentación, aplicado al conjunto de imágenes de soldaduras radiografiadas por el Instituto Federal de Investigación y Análisis de Materiales de Berlín (BAM). Para determinar la calidad de la segmentación generada por el algoritmo, se compara cada imagen del BAM con una imagen binaria ideal, elaborada en forma manual. Este proceso se realiza en un conjunto de diez imágenes que presentan fallas de soldaduras. Los resultados permiten construir la curva ROC y evaluar el rendimiento del algoritmo con la modificación de sus parámetros de entrada.

El resultado del estudio ha permitido desarrollar el siguiente esquema: primero, se utiliza el filtro de la mediana para la reducción del ruido; segundo, se aplica el filtro bottom-hat para la separación de las fallas hipotéticas respecto a su fondo; tercero, se determinan las regiones segmentadas a través de la umbralización binaria; cuarto, se emplean los filtros provenientes de la matemática morfológica para eliminar la sobresegmentación y quinto, se utiliza la transformada de Watershed para separar las regiones internas.

Los resultados del estudio han generado una curva ROC general a un conjunto de diez imágenes. Esta tiene un área  $A_z = 93.58\%$  y su mejor punto operacional tiene 87.83% de sensibilidad y 9.40% de 1-especificidad. El método propuesto sólo realiza la etapa de segmentación, siendo posible obtener mejores resultados si se incluyen las siguientes etapas de la AVI.

Palabras Claves: Segmentación, inspección visual automática, filtro de la mediana, filtro bottom-hat, filtro de canny, umbralización binaria, transformada de watershed, matemática morfológica.

## ABSTRACT

The purpose of this thesis is to develop a digital images filter to segment defects on welds, using digital processing techniques, including noise reduction filters, morphological mathematical operators, edges detections techniques, such as Canny filter, the Watershed transform and distance transform.

The study includes analysis, comparison and how those filters work together in order to enhance the segmentation process applied to a set of radiographic images of welds taken by the Federal Institute for Materials Research and Testing in Berlin (BAM). In order to determine the quality of the algorithm's segmentation each BAM image is compared with an ideal binary image, manually elaborated. A set of ten images of defective welds is used in the process. With the results we will be able to elaborate the ROC curve and evaluate the algorithm performance, modifying the parameters.

The results of this study allow to create the following scheme: first, we use a median filter for noise reduction; second, a bottom-hat filter is applied to separate hypothetical defects from its background; third, a binary threshold determine the segmented regions; fourth, filters from morphological mathematics are applied to discard oversegmentation and fifth, the Watershed algorithm spreads internal regions.

The study results have generated a general ROC curve to a ten images set. The curve has an area  $A_z = 93.58\%$  and on its best operational point has an 87.83% sensibility and 9.40% specificity. The proposed method only process the segmentation phase, so it's possible to enhance its results by including the following AVI phases.

# TABLA DE CONTENIDOS

<b>CAPÍTULO 1</b>	<b>INTRODUCCIÓN</b> .....	<b>1</b>
1.1	ANTECEDENTES Y MOTIVACIÓN .....	1
1.2	DESCRIPCIÓN DEL PROBLEMA .....	3
1.3	SOLUCIÓN PROPUESTA .....	4
1.3.1	<i>Propósitos de la solución</i> .....	5
1.4	OBJETIVOS Y ALCANCES DEL PROYECTO .....	6
1.4.1	<i>Objetivo General</i> .....	6
1.4.2	<i>Objetivos Específicos</i> .....	6
1.4.3	<i>Alcances</i> .....	7
1.5	METODOLOGÍAS Y HERRAMIENTAS UTILIZADAS .....	8
1.5.1	<i>Herramientas de software y hardware utilizadas</i> .....	9
1.6	ORGANIZACIÓN DEL DOCUMENTO.....	9
<b>CAPÍTULO 2</b>	<b>ESTADO DEL ARTE</b> .....	<b>11</b>
2.1	TIPOS Y FALLAS EN LAS SOLDADURAS.....	15
<b>CAPÍTULO 3</b>	<b>FUNDAMENTOS TEÓRICOS</b> .....	<b>18</b>
3.1	INTRODUCCIÓN .....	18
3.1.1	<i>Definición de las estructuras elementales</i> .....	18
3.2	DETECCIÓN DE FALLAS UTILIZANDO TEXTURAS .....	19
3.3	TÉCNICAS DE REDUCCIÓN DEL RUIDO.....	21
3.3.1	<i>Filtro promedio</i> .....	22
3.3.2	<i>Filtro Gaussiano</i> .....	23
3.3.3	<i>Filtro de la mediana</i> .....	24
3.4	MATEMÁTICA MORFOLÓGICA.....	26
3.4.1	<i>Erosión</i> .....	27
3.4.2	<i>Dilatación</i> .....	29
3.4.3	<i>Apertura</i> .....	32
3.4.4	<i>Cerradura</i> .....	33
3.4.5	<i>Detección morfológico de bordes</i> .....	34
3.5	TÉCNICAS DE SEGMENTACIÓN .....	36
3.5.1	<i>Gradiente</i> .....	37
3.5.2	<i>Gradiente de Roberts:</i> .....	39
3.5.3	<i>Gradiente de Prewitt</i> .....	40

3.5.4	<i>Gradiente de Sobel</i> .....	41
3.5.5	<i>Gradiente Laplaciano de la Gaussiana (LoG)</i> .....	42
3.5.6	<i>El método de Canny</i> .....	43
3.5.7	<i>Umbralización</i> .....	44
3.5.8	<i>Transformada de Watershed</i> .....	46
3.5.9	<i>Transformada de la distancia:</i> .....	53
<b>CAPÍTULO 4 DESARROLLO DE LA SOLUCIÓN</b> .....		<b>57</b>
4.1	PREPROCESAMIENTO Y REDUCCIÓN DEL RUIDO.....	58
4.2	FILTRO BOTTOM-HAT .....	59
4.2.1	<i>Eliminación de las señales débiles</i> .....	61
4.3	DETECCIÓN DE BORDES .....	62
4.3.1	<i>Estrategia de Canny</i> .....	62
4.3.2	<i>Estrategia umbralización binaria</i> .....	64
4.4	CORTE DE SECCIONES.....	65
4.4.1	<i>Estrategia de corte de la imagen original</i> .....	66
4.4.2	<i>Estrategia de corte con la transformada de la distancia:</i> .....	67
4.5	ELIMINACIÓN DE LA SOBRESEGMENTACIÓN .....	69
4.5.1	<i>Funciones de Máxima y Mínima:</i> .....	70
4.5.2	<i>Resumen de la aplicación de la imposición de los mínimos</i> .....	74
4.6	APLICACIÓN DE LA TRANSFORMADA DE WATERSHED.....	75
4.6.1	<i>Resumen del proceso de segmentación</i> .....	78
4.7	MÉTODOLOGÍA DE COMPARACIÓN .....	81
4.7.1	<i>Selección de valores de la curva ROC</i> .....	83
<b>CAPÍTULO 5 EXPOSICIÓN DE RESULTADOS</b> .....		<b>84</b>
5.1	ANÁLISIS DE LAS IMÁGENES DEL BAM.....	87
5.1.1	<i>Análisis de la imagen BAM5.tif</i> .....	87
5.1.2	<i>Análisis de la imagen 12R_M.tif</i> .....	89
5.1.3	<i>Análisis de la imagen 13R_M.tif</i> .....	90
5.1.4	<i>Análisis de la imagen 22R_M.tif</i> .....	91
5.1.5	<i>Análisis de la imagen 28R_M.tif</i> .....	92
5.1.6	<i>Análisis de la imagen 31R_M.tif</i> .....	93
5.1.7	<i>Análisis de la imagen 39R_M.tif</i> .....	94
5.1.8	<i>Análisis de la imagen 40R_M.tif</i> .....	95
5.1.9	<i>Análisis de la imagen 106R_M.tif</i> .....	96
5.1.10	<i>Análisis de la imagen 107R_M.tif</i> .....	97
5.1.11	<i>Resultado general del estudio</i> .....	98

5.1.12	<i>Comparación de imagen ideal</i> .....	102
<b>CAPÍTULO 6</b>	<b>DISCUSIÓN DE LOS RESULTADOS</b> .....	<b>104</b>
6.1	DISCUSIÓN DE LOS FILTROS.....	104
6.2	DISCUSIÓN DE LOS RESULTADOS EXPERIMENTALES .....	105
<b>CAPÍTULO 7</b>	<b>REFERENCIAS</b> .....	<b>108</b>
<b>APÉNDICE A</b>	<b>CÓDIGO FUENTE</b> .....	<b>112</b>
7.1	CÓDIGO DE SEGMENTACIÓN DE WATER_5.M .....	112
7.2	CÓDIGO DE COMPARACIÓN DE PÍXELES COMPARA.M.....	113
7.3	CÓDIGO DE SELECCIÓN DE PUNTOS DE LA CURVA ROC .....	113
<b>APÉNDICE B</b>	<b>IMÁGENES IDEALES Y SEGMENTADAS</b> .....	<b>114</b>
7.4	COMPARACIÓN DE BAM5.TIF .....	114
7.5	COMPARACIÓN DE 12R_M.TIF .....	115
7.6	COMPARACIÓN DE 13R_M.TIF .....	116
7.7	COMPARACIÓN DE 22R_M.TIF .....	117
7.8	COMPARACIÓN DE 28R_M.TIF .....	118
7.9	COMPARACIÓN DE 31R_M.TIF .....	119
7.10	COMPARACIÓN DE 39R_M.TIF .....	120
7.11	COMPARACIÓN DE 40R_M.TIF .....	121
7.12	COMPARACIÓN DE 106R_M.TIF .....	122
7.13	COMPARACIÓN DE 107R_M.TIF .....	123

## ÍNDICE DE FIGURAS

FIGURA 1.1 PROCESO DE SEGMENTACIÓN PROPUESTO .....	5
FIGURA 1.2 MODELO DE CASCADA ACTUALIZADO.....	8
FIGURA 2.1 (A) ESQUEMA DE DETECCIÓN DE FALLAS A TRAVÉS DE LA RADIACIÓN SOBRE LA SOLDADURA, (B) RADIACIÓN SOBRE LA FALLA DEL MATERIAL CAPTADO POR LA PLACA RADIOLÓGICA.....	11
FIGURA 2.2 (A) SECCIÓN DE BAM-5 CON FALLAS DE SOLDADURA (B) TIPIFICACIÓN DE LOS TIPOS DE FALLAS, (CORTESÍA DE BAM, BERLÍN).....	17
FIGURA 3.1 PÍXELES EN EL PLANO CARTESIANO .....	19
FIGURA 3.2 SECCIÓN DE BAM-5 CON FALLAS EN LA SOLDADURA (MERY & BERTI, 2003).....	20
FIGURA 3.3 (A) IMAGEN ORIGINAL, (B) APLICACIÓN DEL FILTRO PROMEDIO CON MÁSCARA DE 3x3 .....	22
FIGURA 3.4 REPRESENTACIÓN TRIDIMENSIONAL DEL OPERADOR GAUSSIANO DE 17x17 Y $\sigma = 2$ .....	23
FIGURA 3.5 (A) IMAGEN ORIGINAL, (B) APLICACIÓN DEL FILTRO GAUSSIANO DE 17x17 Y $\sigma = 2$ .....	24
FIGURA 3.6 CÁLCULO DE VALOR DE LA MEDIANA PARA UNA MÁSCARA DE 3x3.....	25
FIGURA 3.7 (A) IMAGEN ORIGINAL, (B) APLICACIÓN DEL FILTRO DE LA MEDIANA CON MÁSCARA DE 3x3.....	25
FIGURA 3.8 CORTE LONGITUDINAL DE UNA IMAGEN Y SU NIVEL DE GRIS .....	27
FIGURA 3.9 APLICACIÓN DEL OPERADOR DE EROSIÓN A LA SEÑAL DE LA FIGURA 3.8.....	27
FIGURA 3.10 REPRESENTACIÓN GRÁFICA DEL OPERADOR DE LA EROSIÓN .....	28
FIGURA 3.11 (A) IMAGEN ORIGINAL BINARIA, (B) APLICACIÓN DE LA EROSIÓN SOBRE (A) .....	29
FIGURA 3.12 CORTE LONGITUDINAL DE UNA IMAGEN.....	30
FIGURA 3.13 APLICACIÓN DE LA DILATACIÓN A LA SEÑAL DE LA FIGURA 3.12.....	30
FIGURA 3.14 REPRESENTACIÓN GRÁFICA DEL OPERADOR DE DILATACIÓN .....	31
FIGURA 3.15 (A) IMAGEN ORIGINAL BINARIA, (B) APLICACIÓN DE LA DILATACIÓN SOBRE (A) .....	31
FIGURA 3.16 (A) IMAGEN ORIGINAL BINARIA, (B) APLICACIÓN DE LA APERTURA SOBRE (A) .....	32
FIGURA 3.17 (A) IMAGEN ORIGINAL BINARIA, (B) APLICACIÓN DE LA CERRADURA SOBRE (A) .....	33
FIGURA 3.18 (A) IMAGEN ORIGINAL BINARIA, (B) DETECTOR MORFOLÓGICO DE BORDES SOBRE (A).....	34
FIGURA 3.19 (A) IMAGEN ORIGINAL BINARIA, (B) DETECTOR MORFOLÓGICO DE BORDES CON ELIMINACIÓN DEL RUIDO SOBRE (A).....	35
FIGURA 3.20 APLICACIÓN DEL GRADIENTE EN LA DETECCIÓN DE BORDES.....	37
FIGURA 3.21 (A) IMAGEN ORIGINAL EN PSEUDOCOLOR, (B) APLICACIÓN DEL GRADIENTE DE ROBERTS .....	39
FIGURA 3.22 (A) IMAGEN ORIGINAL EN PSEUDOCOLOR, (B) APLICACIÓN DEL GRADIENTE DE PREWITT.....	40
FIGURA 3.23 (A) IMAGEN ORIGINAL EN PSEUDOCOLOR, (B) APLICACIÓN DEL GRADIENTE DE SOBEL .....	41
FIGURA 3.24 (A) IMAGEN ORIGINAL EN PSEUDOCOLOR, (B) APLICACIÓN DEL GRADIENTE DE LAPLACIANO .....	42
FIGURA 3.25 USO DE FILTRO DE CANNY CON PARÁMETROS L=0.4 Y H=0.8 (LI, 2004) .....	43
FIGURA 3.26 ESQUEMA DE UMBRALIZACIÓN FIJA A DISTINTOS VALORES DE UMBRAL .....	45
FIGURA 3.27 HISTOGRAMA CON RANGO DE UMBRALIZACIÓN GENERALIZADA .....	45

FIGURA 3.28 CONSTRUCCIÓN DE LAS LÍNEAS DE NIVEL (SOILLE ET AL, 1990).....	46
FIGURA 3.29 PROCESAMIENTO DE REGIONES VECINAS (SANG ET AL, 1998) .....	48
FIGURA 3.30 CAVIDADES Y DIQUES DE WATERSHED (SOILLE ET AL, 1990).....	49
FIGURA 3.31 DISTANCIA GEODÉSICA ENTRE A Y B (MEIJSTER ET AL, 1995) .....	50
FIGURA 3.32 ZONA DE INFLUENCIA GEODÉSICA (MEIJSTER ET AL, 1995) .....	50
FIGURA 3.33 (A) IMAGEN ORIGINAL, (B) SEPARACIÓN DE LA IMAGEN EN SUS NIVELES DE GRIS, (C) GENERACIÓN DEL GRAFO ETIQUETADO DE WATERSHED (MEIJSTER ET AL, 1995) .....	52
FIGURA 3.34 (A) GRAFO ETIQUETADO, (B) GENERACIÓN DE LA IMAGEN BINARIA A PARTIR DE LOS NIVELES DE GRIS, (C) ESQUELETIZACIÓN DEL GRAFO DE WATERSHED (MEIJSTER ET AL, 1995) .....	53
FIGURA 3.35 EJEMPLO DE CÍRCULOS NO CERRADOS (EDDINS, 2002) .....	55
FIGURA 3.36 APLICACIÓN DE LA TRANSFORMADA DE LA DISTANCIA Y LA TRANSFORMADA DE WATERSHED (EDDINS, 2002).....	55
FIGURA 3.37 (A) IMAGEN ORIGINAL EN 2D, (B) REPRESENTACIÓN TRIDIMENSIONAL DE LA APLICACIÓN DE LA TRANSFORMADA DE WATERSHED SOBRE (A) .....	56
FIGURA 4.1 PROCESO DE SEGMENTACIÓN GENERAL .....	57
FIGURA 4.2 (A) IMAGEN ORIGINAL, (B) APLICACIÓN DEL FILTRO DE LA MEDIANA DE 3X3, (C) APLICACIÓN DEL FILTRO GAUSSIANO DE 9X9 CON $\sigma = 1$ , (D) APLICACIÓN DEL FILTRO PROMEDIO DE 5X5.....	58
FIGURA 4.3 (A) IMAGEN ORIGINAL, (B) APLICACIÓN DEL OPERADOR DE LA CERRADURA SOBRE LA IMAGEN ORIGINAL, (C) DIFERENCIA ENTRE LA IMAGEN (A) Y (B), (D) FIGURA 4.3C EN PSEUDOCOLOR.....	60
FIGURA 4.4 (A) IMAGEN CON CORTE DESDE 0.015 A 0.30, (B) OPERACIÓN DE LA MULTIPLICACIÓN DE LA FIGURA 4.4A .....	61
FIGURA 4.5 (A) GENERACIÓN DE BORDES CON EL MÉTODO DE CANNY, (B) DILATACIÓN DE LOS BORDES DE (A), (C) RELLENO DE LAS REGIONES CERRADAS DE (B), (D) EROSIÓN DE LAS ESTRUCTURAS DE (C).....	63
FIGURA 4.6 (A) DILATACIÓN DE LOS BORDES EN MAYOR GRADO, (B) RELLENO DE LAS REGIONES CERRADAS DE LA FIGURA 4.6A.....	64
FIGURA 4.7 (A) IMAGEN BINARIA PRODUCTO DE LA UMBRALIZACIÓN, (B) APLICACIÓN DE LA APERTURA SOBRE LA IMAGEN (A).....	65
FIGURA 4.8 (A) IMAGEN BINARIA, (B) CORTE DE REGIONES A PARTIR DE LA UMBRALIZACIÓN BINARIA .....	66
FIGURA 4.9 REPRESENTACIÓN TRIDIMENSIONAL DEL CORTE DE LA IMAGEN ORIGINAL EN PSEUDOCOLOR .....	67
FIGURA 4.10 (A) SELECCIÓN DE FALLA A TRAVÉS DEL CORTE DE LA IMAGEN ORIGINAL, (B) GENERACIÓN DE ESTRUCTURA UTILIZANDO LA TRANSFORMADA DE LA DISTANCIA .....	68
FIGURA 4.11 (A) APLICACIÓN DE BORDES DE WATERSHED CON LA TONALIDAD ORIGINAL, (B) APLICACIÓN DE BORDES DE WATERSHED CON LA TRANSFORMADA DE LA DISTANCIA .....	69
FIGURA 4.12 (A) SECCIÓN DE BAM-5 EN SU REPRESENTACIÓN BIDIMENSIONAL, (B) REPRESENTACIÓN TRIDIMENSIONAL DE LA IMAGEN (A).....	70
FIGURA 4.13 VALORES DE MÁXIMOS Y MÍNIMOS REGIONALES EN 1 DIMENSIÓN .....	71
FIGURA 4.14 REPRESENTACIÓN DE UNA IMAGEN EN SUS NIVELES DE GRIS .....	72

FIGURA 4.15 CÁLCULO DE LOS MÍNIMOS GLOBALES .....	72
FIGURA 4.16 RESULTADO DE LA APLICACIÓN DE LA IMPOSICIÓN DE LOS MÍNIMOS .....	73
FIGURA 4.17 (A) NIVELES DE GRIS DE LA IMAGEN ORIGINAL, (B) MARCADOR SOBREPUESTO EN LA IMAGEN ORIGINAL, (C) IMAGEN RESULTANTE LUEGO DE LA IMPOSICIÓN DE LA MÍNIMA .....	73
FIGURA 4.18 (A) REPRESENTACIÓN TRIDIMENSIONAL DE UNA SECCIÓN DEL BAM-5, (B) REPRESENTACIÓN TRIDIMENSIONAL DE LA IMPOSICIÓN DE LA MÍNIMA SOBRE (A) .....	74
FIGURA 4.19 (A) IMAGEN BINARIA, (B) CORTE DE SECCIONES DE LA IMAGEN BINARIA SOBRE LA IMAGEN ORIGINAL, (C) CALCULO DE LOS PUNTOS MÍNIMOS DE LA IMAGEN RECORTADA, (D) IMPOSICIÓN DE LOS MÍNIMOS SOBRE LA IMAGEN (B) .....	75
FIGURA 4.20 (A) IMAGEN BINARIA NEGADA, (B) IMAGEN CON IMPOSICIÓN DE LOS MÍNIMOS, (C) SEPARACIÓN DE REGIONES CON WATERSHED, (D) LÍNEAS DE WATERSHED.....	76
FIGURA 4.21 (A) IMAGEN BINARIA SEGMENTADA, (B) IMPOSICIÓN DE LOS CORTES SOBRE LA IMAGEN ORIGINAL.....	77
FIGURA 4.22 (A) SEGMENTACIÓN DE WATERSHED SIN LA SEPARACIÓN DE REGIONES, (B) SEGMENTACIÓN DE WATERSHED SIN EL PROCESAMIENTO DE “HOMOTOPY MODIFICATION” .....	78
FIGURA 4.23 RESULTADO DEL PROCESO DE SEGMENTACIÓN PROPUESTO .....	79
FIGURA 4.24 (A) SEGMENTACIÓN DE LA IMAGEN CON UMBRAL = 3, (B) SEGMENTACIÓN DE LA IMAGEN CON UMBRAL = 5 .....	80
FIGURA. 4.25 DISTRIBUCIÓN DE CLASES DE LAS REGIONES SEGMENTADAS (MERY ET AL, 2003) .....	81
FIGURA.4.26 CURVA ROC CON VARIACIÓN DE $\theta$ (MERY ET AL, 2003) .....	82
FIGURA 4.27 REPRESENTACIÓN DE LAS DIFERENCIAS ENTRE LA IMAGEN IDEAL Y SEGMENTADA .....	82
FIGURA 4.28 (A) CURVA ROC DE LAS PRUEBAS REALIZADAS, (B) SELECCIÓN DE PUNTOS MÁXIMOS DE LA CURVA ROC EN INTERVALOS DE 0.02 DE (A) .....	83
FIGURA 5.1 RELACIÓN ENTRE ÁREA $A_z$ Y VELOCIDAD DE PROCESAMIENTO (MEGAPÍXEL X SEGUNDO) .....	86
FIGURA 5.2 (A) SECCIÓN DE LA IMAGEN BAM-5 IDEAL, (B) SECCIÓN DE LA IMAGEN BAM-5 SEGMENTADA CON EL PROCESO PROPUESTO .....	87
FIGURA 5.3 CURVA ROC DE LA IMAGEN BAM5.TIF.....	88
FIGURA 5.4 CURVA ROC DE LA IMAGEN 12R_M.TIF.....	89
FIGURA 5.5 CURVA ROC DE LA IMAGEN 13R_M.TIF.....	90
FIGURA 5.6 CURVA ROC DE LA IMAGEN 22R_M.TIF.....	91
FIGURA 5.7 CURVA ROC DE LA IMAGEN 28R_M.TIF.....	92
FIGURA 5.8 CURVA ROC DE LA IMAGEN 31R_M.TIF.....	93
FIGURA 5.9 CURVA ROC DE LA IMAGEN 39R_M.TIF.....	94
FIGURA 5.10 CURVA ROC DE LA IMAGEN 40R_M.TIF.....	95
FIGURA 5.11 CURVA ROC DE LA IMAGEN 106R_M.TIF.....	96
FIGURA 5.12 CURVA ROC DE LA IMAGEN 107R_M.TIF.....	97
FIGURA 5.13 CURVA ROC DE LOS VALORES VP, FN, FP, VN REALIZADAS SOBRE EL CONJUNTO DE PRUEBAS CON LOS MISMOS PARÁMETROS.....	98

FIGURA 5.14 VARIACIÓN ENTRE LOS VALORES ÓPTIMOS DE SENSIBILIDAD DE CADA CURVA ROC Y LA PRIMERA COMBINACIÓN DE PARÁMETROS DE LA TABLA 5.12. ....	100
FIGURA 5.15 VARIACIÓN ENTRE LOS VALORES ÓPTIMOS DE 1-ESPECIFICIDAD DE CADA CURVA ROC Y LA PRIMERA COMBINACIÓN DE PARÁMETROS DE LA TABLA 5.12. ....	100
FIGURA 5.16 VARIACIÓN ENTRE EL NÚMERO DE REGIONES SEGMENTADAS DE CADA CURVA ROC Y LA PRIMERA COMBINACIÓN DE PARÁMETROS DE LA TABLA 5.12. ....	101
FIGURA 5.17 (A) IMAGEN BINARIA IDEAL DE BAM-5, (B) IMAGEN BINARIA REALIZADA A TRAVÉS DEL ANÁLISIS DE TEXTURAS (MERY & BERTI, 2003), (C) IMAGEN BINARIA REALIZADA A TRAVÉS DEL PROCESO DE SEGMENTACIÓN PROPUESTO. ....	103
FIGURA 7.1 (A) IMAGEN ORIGINAL BAM-5, (B) IMAGEN BINARIA IDEAL FALLAS DE BAM-5, (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO,.....	114
FIGURA 7.2 (A) IMAGEN ORIGINAL 12R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 3.87%.....	115
FIGURA 7.3 (A) IMAGEN ORIGINAL 13R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 7.47%.....	116
FIGURA 7.4 (A) IMAGEN ORIGINAL 22R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 4.29%.....	117
FIGURA 7.5 (A) IMAGEN ORIGINAL 28R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 4.29%.....	118
FIGURA 7.6 (A) IMAGEN ORIGINAL 31R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 0.58%.....	119
FIGURA 7.7 (A) IMAGEN ORIGINAL 39R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 7.86%.....	120
FIGURA 7.8 (A) IMAGEN ORIGINAL 40R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 3.74%.....	121
FIGURA 7.9 (A) IMAGEN ORIGINAL 106R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 6.17%.....	122
FIGURA 7.10 (A) IMAGEN ORIGINAL 107R_M.TIF, (B) IMAGEN BINARIA IDEAL DE FALLAS DE (A), (C) IMAGEN SEGMENTADA CON EL MÉTODO PROPUESTO, (D) DIFERENCIA ABSOLUTA ENTRE LAS IMÁGENES  B-C  ERROR DE 10.96%.....	123

## ÍNDICE DE TABLAS

TABLA 3.1 MÁSCARA DEL GRADIENTE DE ROBERTS .....	39
TABLA 3.2 MÁSCARA DEL GRADIENTE DE PREWITT.....	40
TABLA 3.3 MÁSCARA DEL GRADIENTE DE SOBEL .....	41
TABLA 5.1 RESUMEN DE LAS IMÁGENES SEGMENTADAS Y SUS MEJORES VALORES DE SENSIBILIDAD, 1- ESPECIFICIDAD, ÁREA $A_z$ Y TIEMPO DE PROCESAMIENTO .....	85
TABLA 5.2 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN BAM5.TIF .....	88
TABLA 5.3 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 12R_M.TIF .....	89
TABLA 5.4 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 13R_M.TIF .....	90
TABLA 5.5 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 22R_M.TIF .....	91
TABLA 5.6 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 28R_M.TIF .....	92
TABLA 5.7 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 31R_M.TIF .....	93
TABLA 5.8 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 39R_M.TIF .....	94
TABLA 5.9 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 40R_M.TIF .....	95
TABLA 5.10 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 106R_M.TIF .....	96
TABLA 5.11 MEJORES PUNTOS DE LA CURVA ROC DE LA IMAGEN 107R_M.TIF .....	97
TABLA 5.12 RESULTADOS GENERALES DE LOS PUNTOS DE LA CURVA ROC GENERAL .....	99
TABLA 5.13 COMPARACIÓN ENTRE EL FILTRO DESARROLLADO Y EL MÉTODO DE ANÁLISIS DE TEXTURAS DE LA IMAGEN BAM-5 .....	102

# **CAPÍTULO 1 INTRODUCCIÓN**

## **1.1 ANTECEDENTES Y MOTIVACIÓN**

La visión por computador es un factor clave para la implementación de la calidad total dentro de los diferentes procesos de automatización industrial. La utilización de esta tecnología por parte de las empresas lleva consigo una ventaja competitiva, pudiendo tener un aumento de producción, mejora en la calidad de los productos, como también la reducción de costos de fabricación (González, 1992). Además permite inspeccionar los procesos de producción en forma precisa, facilitando la cuantificación de las variables de calidad. Esta tecnología no se ha implementado fuertemente en el país ya que aún se encuentra en investigación y desarrollo, por este motivo, es necesario conocer las posibilidades reales de su aplicación, dependiendo del tipo de sistema donde se implantará.

El proceso que permite utilizar la visión por computador de forma automatizada es conocido como inspección visual automática (AVI) y su objetivo consiste en determinar si un producto se encuentra dentro o fuera del rango de aceptación en el proceso de fabricación. Para ello se utilizan distintas técnicas de procesamiento digital de imágenes (Newman & Jain, 1995). La AVI es una denominación que engloba un gran conjunto de análisis y algoritmos que se dividen por una serie de etapas de procesamiento, dentro de las cuales se encuentran: la formación de la imagen, preprocesamiento, segmentación, extracción de características y clasificación.

Una de las principales líneas de investigación de la AVI, es el proceso de reconocimiento de fallas en forma automática, debido a que la automatización permite establecer políticas y formas de control precisas y objetivas, en cambio los sistemas manuales están afectos al agotamiento y rutina por parte del operador, causando un control deficiente o inconstante (Liao, 2003). Existen dos condiciones básicas que un sistema AVI debe cumplir para mejorar la calidad de los productos: el primer caso es la eficiencia, la cual dice relación con la menor cantidad de falsos

positivos y negativos; el segundo es la rapidez; la idea es que el proceso de producción no se vea afectado por el tiempo que toma la inspección y por lo tanto aumente o mantenga al menos la velocidad de producción.

Las aplicaciones de la AVI se pueden encontrar en distintas áreas, como por ejemplo la detección de fallas en piezas fundidas, circuitos impresos, soldaduras, vidrios, textiles, alimentos, láminas de silicio, cueros, etc. Sin embargo, hay que notar que cada análisis está directamente asociado al tipo de material que se desea analizar. Difícilmente un método diseñado para el reconocimiento de fallas de un material, se podrá aplicar a otro (Mery, 2002).

Los métodos actuales pretenden disminuir el número de falsos positivos y falsos negativos. Los falsos positivos están constituidos por el número de productos que estando sin defectos son considerados con fallas, en cambio, los falsos negativos son el número de productos que estando con fallas, son considerados sin fallas. Dependiendo del tipo de aplicación en que se encuentre inserto el análisis, se ajusta a cualquiera de los dos estados. En el caso de los falsos negativos, puede ser relevante cuando los productos requieran un máximo de calidad y seguridad, tales como los procesos de producción de alimentos, o medicamentos; estos últimos no aceptan productos con fallas, dadas las consecuencias negativas para las personas que los ingieren. En el caso de los falsos positivos, puede que sea necesario ajustar los parámetros de la AVI para que estos dejen pasar un mayor conjunto de productos. Esto se traduce directamente en una medida económica, ya que se puede producir una mayor cantidad de productos, aún cuando exista la probabilidad que algunos tengan fallas. La disminución de estos dos parámetros es uno de los objetivos principales de la detección de fallas, pero es difícil de lograr ya que depende en gran medida del tipo de producto o material que se esté analizando y del tipo de ajuste o sintonía que requiera la AVI.

La segmentación es una de las etapas iniciales dentro del proceso de la AVI, no obstante, su aplicación permite separar y detectar en una primera fase regiones de interés, las que posteriormente son clasificadas. La segmentación es considerada comúnmente como una de las tareas más complejas en el procesamiento de imágenes (González, 1992). La investigación en esta área es extensa, pero es específica al material que se analiza. En el caso de la presente tesis,

se analizan distintas estrategias y métodos, los que están orientados a la detección de fallas en imágenes de soldaduras.

En resumen, esta memoria abarca el área de la segmentación ya que esta es vital para la extracción de características, dado que permite determinar todas las regiones con posibles fallas, sin embargo, para discriminar las posibles falsas alarmas de las potenciales fallas, es necesario un clasificador. Se pretende que la calidad de la detección de fallas mejore debido a la disminución de falsos positivos y negativos, y que sus resultados puedan ser utilizados en las siguientes etapas de la AVI.

## 1.2 DESCRIPCIÓN DEL PROBLEMA

El problema consiste en diseñar e implementar un algoritmo que permita determinar todas las regiones con fallas hipotéticas de soldaduras, mediante el análisis de imágenes digitales. La calidad en la detección de las fallas es un punto primordial en la construcción de la solución, por la cual esta debe ser cuantificable. Para realizar esto, se debe utilizar un algoritmo de comparación que precise efectivamente la cantidad de falsos positivos y falsos negativos encontrados en la detección de la falla. La comparación se realiza utilizando el resultado experimental de la imagen BAM-5, analizado en (Mery & Berti, 2003). A partir de la comparación se debe confeccionar la curva ROC (Egan, 1975), de este modo, se representa gráficamente el rendimiento del algoritmo en la detección de fallas. El algoritmo analizará el conjunto de imágenes de soldaduras radiografiadas por el Instituto Federal de Investigación y Análisis de Materiales de Berlín (BAM).

En el desarrollo de la tesis se estudiarán otras estrategias de segmentación, como la utilización del método de Canny (Canny, 1986) para la detección de bordes y del uso de la transformada de la distancia (Breau et al, 1995) para complementar la segmentación de Watershed, además de otras técnicas de procesamiento digital para la reducción del ruido como el filtro Gaussiano, el filtro promedio y el filtro de la mediana. La idea consiste en realizar comparaciones y evaluaciones respecto a la calidad y al tipo de segmentación generada. Luego de este proceso, se

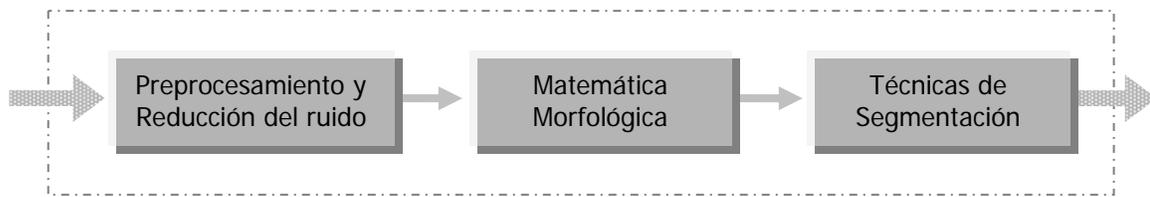
debe establecer una comparación con otros métodos, basado en el filtro LoG (Mery & Filbert, 2002), y con ello evaluar la solución desarrollada.

Unas de las características del algoritmo, consiste en la utilización de la transformada de Watershed como herramienta de segmentación (Beucher et al, 1979), no obstante, el uso de esta técnica conlleva al problema de la sobresegmentación. Para ello se debe utilizar un método que evite esto y permita generar conjuntos conexos de mayor relevancia. Por lo tanto, la solución del problema está condicionada al uso de técnicas de procesamiento digital que apuntan a desarrollar una herramienta de segmentación basada en diferentes métodos. El enfoque consiste en solucionar tres áreas: disminución de ruido, umbralización y segmentación.

### **1.3 SOLUCIÓN PROPUESTA**

La solución está compuesta por un conjunto de técnicas de procesamiento digital, separadas en fases independientes; esto permite analizar y cuantificar la calidad en cada fase, de tal manera que, si se requiere un ajuste en algún punto del proceso, no es necesario modificar todo el algoritmo, sólo se altera la variable que controle dicha fase, permitiendo un cambio en el resultado global. Dentro del conjunto de técnicas utilizadas, se aplican distintos tipos de filtros para detectar fallas, separarlas del fondo de la imagen y segmentarlas, además de incorporar un análisis de diferentes técnicas de reducción de ruido para mejorar la calidad de la imagen.

En la figura 1.1 se presenta un modelo general del proceso compuesto por el preprocesamiento, la matemática morfológica y las técnicas de segmentación. El preprocesamiento tiene la finalidad de remover la mayor cantidad de ruido, sin que los bordes de las fallas pierdan su definición, luego se utiliza el proceso de la matemática morfológica, el cual pretende disminuir el ruido causado por la umbralización binaria, además de permitir su uso a través de otras técnicas como el filtro bottom-hat. El proceso finaliza con la aplicación de las técnicas de segmentación, permitiendo generar los bordes de las fallas y la separación de estas del fondo de la imagen.



*FIGURA 1.1 Proceso de segmentación propuesto*

La idea es que el conjunto de técnicas utilizadas permita mejorar la calidad de la segmentación en la detección de las fallas hipotéticas y, a su vez minimizar los falsos positivos y negativos. Según lo anterior, el proceso a diseñar está compuesto por un conjunto de tareas en las cuales se utilizará la herramienta MATLAB. En forma general, se presentan las fases que se deben elaborar para analizar una imagen con el algoritmo propuesto:

- Procesar la imagen a través de filtros para la reducción del ruido.
- Procesar la imagen anterior a través de un filtro de umbralización binaria.
- Obtener sólo las zonas de las fallas hipotéticas a través de operaciones sobre la imagen binaria.
- Limitar la cantidad de uniones que realiza Watershed en la unión de los diques, para evitar su sobresegmentación.
- Utilizar la transformada de Watershed, para unir los bordes incompletos y limitar las fallas hipotéticas.
- Una vez detectada la falla y analizada, indicar su ubicación.
- Evaluar estadísticas de desempeño para la detección de fallas utilizando las curvas ROC.

### **1.3.1 Propósitos de la solución**

Muchas veces sucede que las imágenes que se analizan a través de la AVI tienen una gran cantidad de ruido; dada esta problemática, se debe disminuir la cantidad de error en la segmentación utilizando para ello el filtro de la mediana, luego un filtro de umbralización y finalmente, la transformada de Watershed en combinación con los resultados anteriores. Se pretende que la calidad en la detección de fallas mejore debido a la disminución de falsos

positivos y negativos, y que sus resultados puedan ser utilizados en las siguientes etapas de la AVI, en combinación con otras técnicas. Para verificar la calidad de la solución, se utiliza la curva ROC<sup>1</sup> (Egan, 1975), la cual mide el rendimiento de una clasificación de dos clases. Para ello se debe determinar la prueba de ‘Sensibilidad’ y la ‘1-especificidad’. Los resultados entregados por la curva indican las siguientes condiciones:

- Si la prueba es perfecta, hay una región en la que cualquier punto de corte tiene sensibilidad y 1-especificidad igual a 1; esto significa que la segmentación ha sido ideal y tiene un área equivalente  $A_z = 1$ .
- Si la prueba no entrega resultados coherentes, quiere decir que se tiene la misma proporción de falsos negativos como verdaderos positivos. En este caso la segmentación ha sido aleatoria y tiene un área equivalente  $A_z = 0.5$ .

## 1.4 OBJETIVOS Y ALCANCES DEL PROYECTO

### 1.4.1 Objetivo General

- Desarrollar un filtro de imágenes que permita segmentar fallas en soldaduras, utilizando técnicas de procesamiento digital de imágenes.

### 1.4.2 Objetivos Específicos

- Utilizar técnicas modernas de procesamiento digital de imágenes tales como el método de Canny, la transformada de Watershed, operadores matemáticos morfológicos y filtros de atenuación del ruido en imágenes de soldaduras.
- Analizar el conjunto de imágenes de soldaduras radiografiadas por el Instituto Federal de Investigación y Análisis de Materiales, BAM.

---

<sup>1</sup> Una explicación más detallada de la curva ROC se encuentra en la subsección 4.7.

- Comparar el método desarrollado con otras soluciones de la segmentación de fallas en soldaduras tales como el método LoG, utilizando como plataforma de desarrollo el software MATLAB.
- Evaluar el rendimiento del método propuesto para medir su eficiencia en la detección de fallas utilizando las curvas ROC.

### 1.4.3 Alcances

La idea propuesta consiste en desarrollar un algoritmo de segmentación aplicado a las imágenes con fallas de soldaduras del BAM, sin embargo, los filtros a utilizar presentan algunos inconvenientes. La utilización de Watershed por sí sola no basta, ya que cuando la imagen tiene demasiado ruido, se produce una sobresegmentación. La solución consiste en realizar algún preprocesamiento antes de utilizar la transformada. Una posible idea es emplear Watershed sólo en las regiones factibles de tener fallas; para ello es necesario realizar un procesamiento que permita señalar dichas regiones.

Los filtros de umbralización binaria están afectos al parámetro de corte, lo que significa que la cantidad de regiones encontradas dependerá del umbral ingresado. El problema consiste en determinar el parámetro preciso para cada tipo de imagen analizada. Este valor permitirá obtener la sintonía o ajuste que requiera la AVI.

Luego de analizar las distintas estrategias para desarrollar Watershed, el algoritmo propuesto por (Vincent, 1991) es el de mejor calidad y rendimiento, además se encuentra integrado en el software MATLAB. Esto es de gran ayuda, ya que se dispone de una gran cantidad de funciones y filtros de imágenes implementados; esto también se cumple para el desarrollo de los algoritmos de umbralización binaria y los distintos algoritmos de disminución del ruido tales como el filtro promedio, Gaussiano y de la mediana.

## 1.5 METODOLOGÍAS Y HERRAMIENTAS UTILIZADAS

Se propone utilizar una metodología proveniente de la Ingeniería de Software. Este proceso define el orden especificando qué, quién y cuándo se realiza cada fase. De acuerdo a lo señalado anteriormente, es necesario definir las fases del proyecto en forma específica y sin la aparición de posibles ambigüedades.

Se hace necesario considerar cada una de las actividades del proceso como una fase discreta, lo que implica que una vez terminada una etapa, el desarrollo pase a la siguiente fase. Para realizar esto, el modelo definido para el desarrollo del proyecto es el de Cascada Actualizado (Somerville, 2000).

En la figura 1.2 se presenta el modelo de cascada actualizado. Este proceso se divide en fases claramente especificadas, que pueden variar dependiendo de los autores, pero conservan siempre la misma idea, en la cual no puede empezar una fase hasta que no se termine la anterior. El término ‘actualizado’ dice relación con la posibilidad de detenerse en una etapa determinada del proyecto, revisar si es necesario, volver atrás hasta una etapa determinada, realizar modificaciones y continuar con las siguientes etapas.

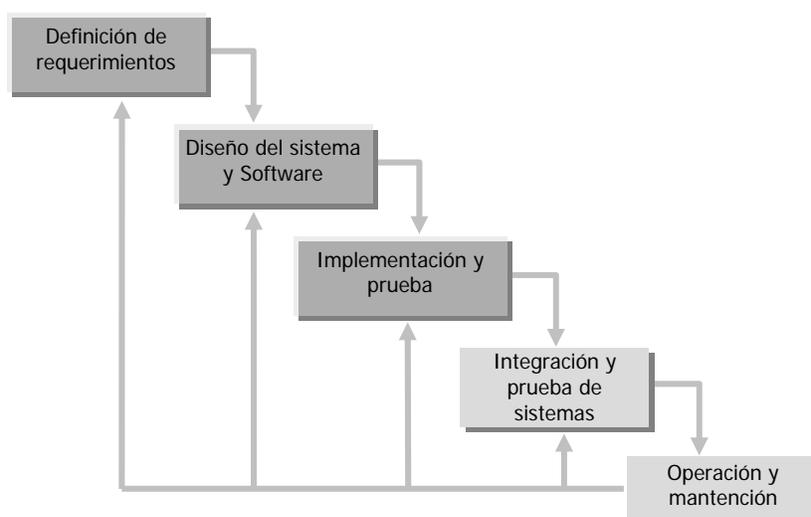


FIGURA 1.2 Modelo de cascada actualizado

### 1.5.1 Herramientas de software y hardware utilizadas

La principal herramienta de software matemático utilizada es MATLAB R13, versión 6.5.0.180913a y el “*Toolbox*” de procesamiento de imágenes versión 3.2. Esta última incluye la mayoría de las funciones digitales que se utiliza en el desarrollo del trabajo. El sistema operativo utilizado es Microsoft Windows XP Professional 2002 versión 5.1.2600.

Dentro de las principales características del hardware se incluye un procesador AMD Athlon XP 2400+ con una frecuencia de reloj de 2.0 GHZ. Además se dispone de 1 GB de memoria RAM DDR con un bus de 330 MHZ. El disco duro es de 80 GB con una velocidad de 7200 RPM y un tiempo de acceso de 8.5 ms., con un bus ATA100.

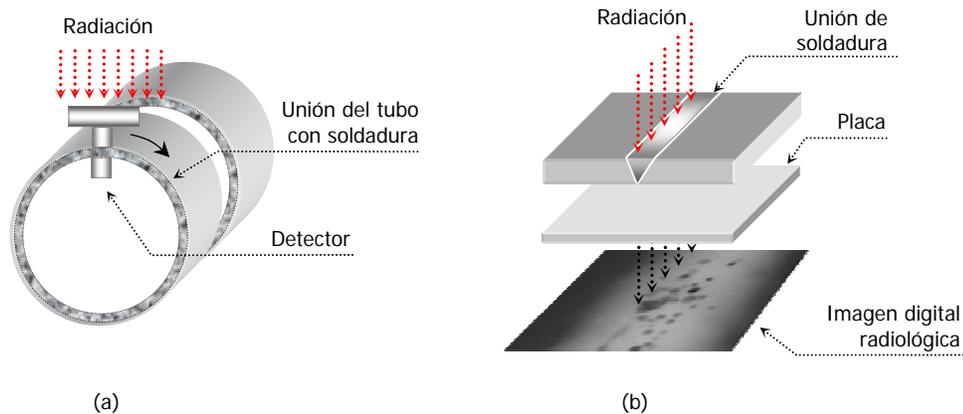
## 1.6 ORGANIZACIÓN DEL DOCUMENTO

- El documento se ha dividido en seis capítulos. El segundo capítulo presenta el estado del arte respecto a la detección de fallas en soldaduras, su aplicación y desarrollo actual, además de una revisión de los distintos tipos de fallas.
- El tercer capítulo expone los fundamentos teóricos del problema. Se presenta un breve estudio de los distintos métodos de reducción de ruido utilizados. También se ha extendido la investigación a la matemática morfológica y la manera en que esta técnica permite la manipulación de las imágenes binarias. Luego se presenta las técnicas de segmentación, dentro de las cuales están las formulaciones derivativas tales como los filtros que utilizan la función del gradiente, la umbralización, el filtro de Canny, y para finalizar con el estudio de la transformada de Watershed y de la distancia.
- El cuarto capítulo presenta el desarrollo de la solución. Se utilizan los resultados del tercer capítulo para determinar los filtros que se emplean en la construcción de la solución. Además se presenta los resultados de cada fase del proceso y cómo la combinación de los filtros permite una mejor calidad en la segmentación.

- 
- El quinto capítulo presenta los resultados del estudio sobre el conjunto de imágenes del BAM. Para determinar el rendimiento del algoritmo, se emplea la curva ROC en cada imagen analizada, junto con los mejores parámetros de entrada del algoritmo. Además se presenta la construcción de la curva ROC general al proceso, siendo consideradas todas las imágenes del estudio para su desarrollo.
  
  - El último capítulo presenta la discusión de los filtros utilizados, los resultados experimentales, y futuras mejoras que puede tener el método propuesto en el estudio.
  
  - En el apéndice A se presenta el código fuente del algoritmo. En el apéndice B, se presenta los resultados del proceso de segmentación, especificando la imagen original, la imagen binaria ideal, la imagen con el resultado del proceso de segmentación y la resta absoluta entre la imagen ideal y segmentada.

## CAPÍTULO 2 ESTADO DEL ARTE

Existen estructuras que utilizan la soldadura en forma crítica, tales como equipos de alta presión, compuestos químicos, etc., en donde cualquier tipo de falla puede generar un resultado catastrófico. Debido a esto, existen formas convencionales para detectar las fallas en soldaduras a través de la inspección visual de imágenes radiográficas. Estas imágenes son generadas utilizando los rayos-X o rayos- $\gamma$  los cuales penetran el material, generando una imagen radiológica al ser expuesta a una placa fotográfica. Las fallas quedan reveladas debido a la variación de la densidad del material (figura 2.1). Sin embargo, la interpretación manual de las fallas genera un resultado subjetivo, impreciso, de gran consumo de tiempo e inconsistente, siendo dependiente de un inspector para su análisis (Liao, 2003).



*FIGURA 2.1 (a) Esquema de detección de fallas a través de la radiación sobre la soldadura, (b) Radiación sobre la falla del material captado por la placa radiológica.*

Debido al problema de la detección manual, existe en la actualidad una gran cantidad de trabajos e investigaciones sobre la detección de fallas en soldaduras que utilizan el esquema de análisis no destructivo (NDT). El objetivo consiste en desarrollar un método automático para la detección de fallas que permita tener una inspección precisa y objetiva. Algunos de los aportes más significativos sobre el tema se presentan a continuación.

A principios de los 90, Gayer (Gayer et al, 1990) presentó un método para el análisis de texturas en la detección de fallas en soldaduras. Este método se compone de dos etapas: primero, se asume que los defectos son menores que las estructuras regulares de las piezas analizadas. Se utiliza la transformada rápida de Fourier que es calculada fila por fila o columna por columna en ventanas de 32x32. Cuando la suma de las altas frecuencias de la ventana es mayor que un umbral, la ventana es marcada como una falla potencial. Segundo, consiste en identificar y localizar las fallas verdaderas. En este punto existen dos variantes; la primera consiste en realizar una comparación entre la imagen con la falla potencial y una falla típica almacenada anteriormente como una librería de fallas. Si existe una gran semejanza entre las dos imágenes, la falla potencial es clasificada como falla verdadera. La segunda variante crea una imagen libre de fallas, interpolando una función spline sobre cada línea de la imagen, sin considerar las regiones con fallas. Cuando existe una diferencia importante entre estas dos imágenes, se identifican las fallas reales.

En 1994, Lawson y Parker (Lawson & Parker, 1994) proponen un sistema de detección de fallas en imágenes de rayos-X, utilizando una red neuronal artificial (ANN). El método genera una imagen binaria de la imagen analizada, donde cada píxel de la imagen es 0 cuando es una estructura regular y 1 cuando se ha detectado una falla. Los autores utilizan una de las dos capas ocultas de la ANN, en la cual, la señal de entrada corresponde a una ventana de  $m \times m$  niveles de gris de la imagen radiológica. La salida de la señal es un píxel de la imagen centrada en la imagen binaria. En la etapa del entrenamiento se ha utilizado una segmentación basada en umbrales adaptativos. Según los autores, los resultados indican que la detección de fallas de la ANN es superior al método de segmentación que utiliza el umbral adaptativo.

En 1996, Li y Liao (Li & Liao, 1996), desarrollan un método de detección de fallas basado en la construcción de una curva Gaussiana. La idea consiste en analizar las variaciones de cada línea horizontal de la imagen. Según las observaciones de los autores, la mayoría de las líneas analizadas se puede modelar con una curva Gaussiana, dada que esta última genera una distribución en forma de campana. De acuerdo a esto, se define tres categorías para las fallas: defectos de picos, defectos de canales y defectos de cavidades inclinadas. Debido a los defectos en la calidad de las imágenes, es necesario realizar un ajuste en la imagen para remover el fondo.

Para ello se ajusta cada línea de la imagen utilizando el valor promedio y ajustando su escala para que la curva de cada línea tenga el mismo tamaño. Después de la normalización, un ajuste en el nivel del umbral es utilizado para remover el fondo de la imagen. A continuación se utilizan dos tipos de curvas spline para facilitar la detección de las fallas. Los resultados indican que más del 90% de los defectos son detectados correctamente.

Los mismos autores anteriores, desarrollan en 1998 un método de detección basado en el ajuste de la curva (Liao & Li, 1998). La idea consiste en simular una imagen libre de fallas utilizando una frecuencia espacial baja, en comparación con las altas frecuencias de la imagen con fallas. La imagen simulada es creada a partir del ajuste de cada línea vertical utilizando una función polinomial. Los defectos son detectados cuando la diferencia entre la imagen obtenida y la imagen original es considerable.

En el año 2002, un nuevo método para la detección de fallas en soldaduras fue presentado por Sofía y Redouane (Sofía & Redouane, 2002). La detección utiliza la metodología del reconocimiento de patrones, la cual se compone de: i) Segmentación: se realiza utilizando el algoritmo de Watershed, además de las operaciones morfológicas tales como la erosión y la dilatación, ii) Extracción de características: las regiones segmentadas son medidas de acuerdo a sus características (variación del diámetro, dirección principal de inercia basada en los momentos invariantes), iii) Clasificación: Las características de cada región son analizadas y clasificadas utilizando un clasificador de vecinos  $k$ -ceranos. Los autores concluyen que el método propuesto es robusto y tiene un alto índice en la detección de fallas.

En ese mismo año (Silva et al, 2002) propone un método de clasificación de fallas de soldaduras. La primera etapa consiste en utilizar el filtro de la mediana y una técnica de mejora del contraste. Luego se utiliza el esquema de reconocimiento de patrones mencionado anteriormente. i) Los defectos potenciales son segmentados, ii) Las características geométricas y niveles de gris (contraste ( $C$ ), posición ( $P$ ), relación de forma ( $a$ ), relación ancho/área ( $e/A$ ), relación longitud/área ( $L/A$ ) y redondez ( $R$ )) son extraídas. La correlación entre los defectos y cada clase de falla considerada, es analizada utilizando un análisis de coeficiente de correlación lineal, iii) Las características más relevantes son utilizadas como entrada de datos de un clasificador lineal

jerárquico. Los resultados indican que las características de  $P$  y  $e/A$  son capaces de clasificar las clases de socavación y falta de penetración. Sin embargo, las seis características mencionadas requieren obtener un alto nivel de rendimiento para clasificar la porosidad y la escoria.

Wang y Liao (Wang & Liao, 2002) utilizan dos algoritmos supervisados: *Fuzzy k-nearest neighbour* (K-NN) y una red neuronal perceptrón multicapa (MLP) para la clasificación de las fallas de soldaduras. El proceso se inicia con la reducción del ruido a través del filtro de la mediana, un realce del contraste con una modificación del histograma, y el método de substracción del fondo (BSM). En la extracción de características se utiliza: la distancia desde el centro, circularidad, desviación estándar, radio promedio, elongación, etc. Finalmente se utiliza el método (K-NN) y el (MLP) para la clasificación. Los resultados indican que el método (MLP), presenta una ventaja sobre el (K-NN) con un 92.39% y un 91.57% de clasificación respectivamente.

En el año 2003, Liao (Liao, 2003) propone utilizar un sistema experto difuso, el cual toma las mismas características del método de (Wang & Liao, 2002). Los resultados indican que este método produce mejores resultados en la clasificación que los métodos (K-NN) y (MLP). Para solucionar el problema de adquisición de conocimiento se utilizaron dos máquinas de aprendizajes, en la cual una de ellas mejora a la otra a través de un algoritmo genético y de esta manera, se determina un número óptimo de particiones en el dominio del espacio.

Ese mismo año, Mery y Berti (Mery & Berti, 2003), presentan una nueva metodología basada en el análisis de texturas. La textura es una de las características más importante en el reconocimiento de patrones, pero ha sido poco utilizada para el análisis de imágenes digitales del NDT. El estudio contempla el análisis de dos tipos de características de las texturas: características basadas en la matriz de ocurrencia y características basadas en la función Gabor. La aproximación propuesta utiliza la siguiente metodología: i) Segmentación: se utiliza el detector de bordes LoG, ii) Extracción de características: las características de los potenciales defectos son extraídas, iii) Clasificación: Las características más relevantes son utilizadas como datos de entrada de un clasificador estadístico. El mejor resultado se ha obtenido con un clasificador polinomial, con 91% de detección de fallas y 8% de falsas alarmas.

De la bibliografía revisada, se observa una gran cantidad y diferencias de metodologías aplicadas en la detección de fallas de soldaduras, tales como la interpolación de curvas del fondo de la imagen, redes neuronales, características geométricas, aplicación de la matemática morfológica, transformada de Watershed, análisis de texturas, etc. La investigación en esta área continúa, debido a que no existen resultados satisfactorios que permitan detectar la totalidad de las fallas, sin tener falsas alarmas. Además no es posible determinar cual de las líneas de investigación mejora el resultado global, ya que cada una de ellas es factible de perfeccionar. El estudio de este trabajo se justifica por el desarrollo de un nuevo método de segmentación que mejore el proceso de detección automática de fallas de soldadura. Además, la presente investigación está dedicada a desarrollar una metodología que reúna algunas de las mejores características de los estudios revisados, tales como la aplicación del filtro de la mediana (Silva et al, 2002), la comparación de una imagen real y una imagen libre de fallas (Liao & Li, 1998), el uso de la matemática morfológica y el algoritmo de Watershed<sup>2</sup> (Sofía & Redouane, 2002).

## 2.1 TIPOS Y FALLAS EN LAS SOLDADURAS

La soldadura conecta piezas de metal entre sí a través de la aplicación de calor, pudiendo ser con o sin presión, algunos tipos de soldaduras son por calentamiento y fusión de metales blandos, como también soldaduras bajo el agua (Bresler et al, 1973).

En la actualidad existen distintos tipos de soldaduras, dependiendo del tipo de unión y material que se requiera unir. Se definen tres grandes procesos: soldaduras a presión, soldadura de fusión y finalmente, soldadura por calentamiento y fusión de metales blandos. El más común de estos tipos es la soldadura de fusión, utilizado generalmente en trabajos de acero estructural, conocido como soldadura de arco metálico; este esquema genera el calor a través de un arco eléctrico formado por un electrodo de acero y las partes que se van a soldar. El calor del arco funde el metal y el electrodo, a medida que este se desplaza a lo largo de la soldadura.

---

<sup>2</sup> Una explicación más detallada del algoritmo de Watershed se encuentra en la subsección 3.5.8

Respecto a la calidad de la soldadura de arco metálico, existen tres factores metalúrgicos que la determinan: la estructura cristalina, la solubilidad de los gases y la oxidación (Bresler et al, 1973).

- Cuando el acero llega a una temperatura crítica de  $815^{\circ}\text{C}$ , tiene una estructura cristalina casi uniforme, denominada *austenita*. A medida que se enfría lentamente, la estructura cambia a un material dúctil denominado *perlita*. Si el acero es enfriado rápidamente, la austenita cambia su estructura, transformándose en un material quebradizo, compuesto en mayor parte por *martensita*. Es por ello la importancia de la regulación de la temperatura, ya que determina si el acero será dúctil o frágil después de la soldadura. Una velocidad de enfriamiento lento genera un acero dúctil; un enfriamiento rápido genera un acero duro pero frágil.
- Respecto a la solubilidad de los gases, a altas temperaturas el acero puede retener una mayor cantidad de gases que a temperaturas más bajas, debido a esto es necesario proteger la soldadura de los gases, ya que en el proceso de enfriamiento la soldadura puede desprender bolsas de gases conocidas como porosidades, o bien pueden quedar retenidos en la soldadura produciendo cambios químicos en el metal.
- El proceso de oxidación durante la soldadura puede producir óxidos gaseosos o sólidos. Estas reacciones generan porosidades, y los sólidos pueden generar escoria en la soldadura. Esta reacción es altamente perjudicial ya que la soldadura puede perder su resistencia y tornarse quebradiza.

De acuerdo a la figura 2.2, los distintos tipos de fallas son reflejados en la imagen radiológica y están definidos según sus niveles de gris, forma y tamaño. En el caso de la falla de “falta de penetración”, esta se muestra como una línea a lo largo de la soldadura. La falta de penetración se define como la falta de inclusión de soldadura para fundirse en el metal, esto puede deberse a: ángulo insuficiente, técnica inapropiada, uso incorrecto del electrodo, velocidad excesiva o corriente insuficiente. Debido a esta falla, se generan otras, ya que la contracción de los esfuerzos sobre la soldadura genera grietas o fisuras.

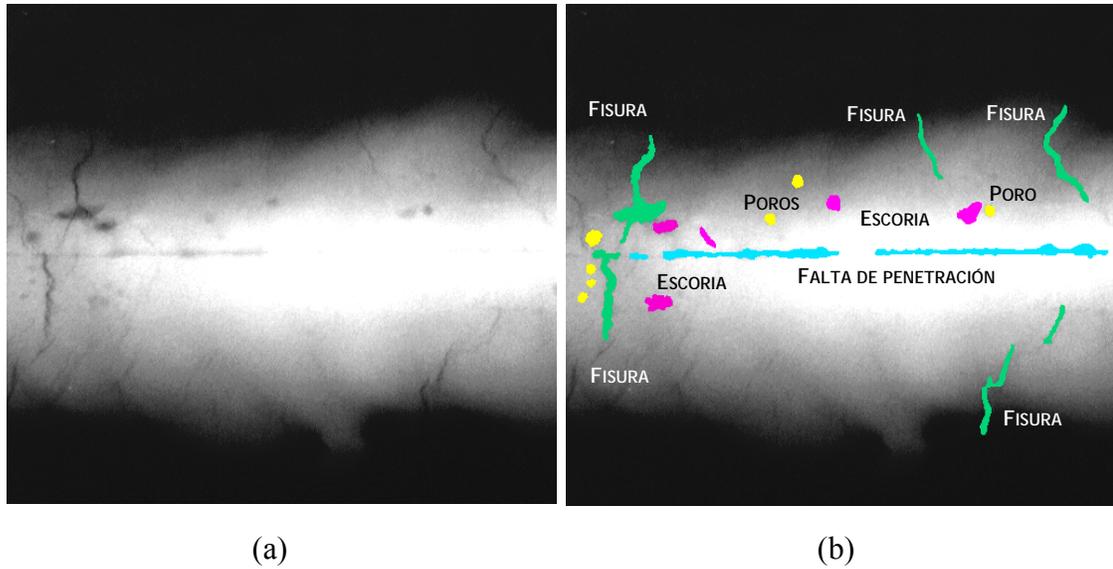


FIGURA 2.2 (a) Sección de BAM-5 con fallas de soldadura (b) Tipificación de los tipos de fallas, (cortesía de BAM, Berlín)

La escoria tiene una forma alargada o globular producto de la inclusión de óxidos metálicos y otros componentes sólidos. Puede evitarse si se escoge correctamente la composición química del electrodo y de su recubrimiento, de manera que no reaccionen con el metal a soldar.

Las porosidades se deben a la inclusión de bolsas de gas en la soldadura; debido a una reducción de temperatura en la cual los gases quedan retenidos. También puede ser generada por reacciones químicas de los gases.

# **CAPÍTULO 3 FUNDAMENTOS TEÓRICOS**

## **3.1 INTRODUCCIÓN**

En este capítulo se describen las distintas técnicas que se utilizan en el desarrollo de la solución. Según el enfoque propuesto en la sección 1.3, se procede a dividir el desarrollo en: técnicas de reducción del ruido, matemática morfológica y técnicas de segmentación. Cada etapa se emplea en forma independiente dentro del proceso. Debido a esto, la variación en la calidad de una etapa puede generar un cambio en el resultado final. Por ello, es necesario analizar las características de cada fase y emplear la mejor secuencia de técnicas que permita mejorar el proceso de detección de fallas.

En la primera sección se describe el proceso de detección de fallas utilizando texturas, luego se presentan las técnicas de reducción del ruido y se analiza el método de umbralización binaria, en especial la utilización de la matemática morfológica. A continuación se describe el proceso de segmentación y sus distintas variantes, dentro de las cuales se encuentra el filtro de Roberts, Prewitt, Sobel, Laplaciano de la Gaussiana y el método de Canny. Finalmente, se presenta la transformada de Watershed y la transformada de la distancia, esta última como herramienta de apoyo para el proceso de segmentación.

### **3.1.1 Definición de las estructuras elementales**

Una estructura elemental está compuesta de un patrón específico, de puntos discretos relativos a un origen. En la figura 3.1 se utiliza coordenadas cartesianas usadas convenientemente en una malla rectangular en donde se representan elementos de la imagen. Cada punto de la matriz tiene un valor. En estructuras de elementos simples, como las imágenes binarias los elementos tienen dos valores, 0 ó 1. En elementos más complejos, usados en operaciones morfológicas de escalas

de grises, los píxeles tienen valores entre 0 y  $(2^n - 1)$  (siendo  $n$  el número de niveles de gris); generalmente se utilizan escalas de gris con valores entre 0 y 255, siendo esta última de 8 bits.

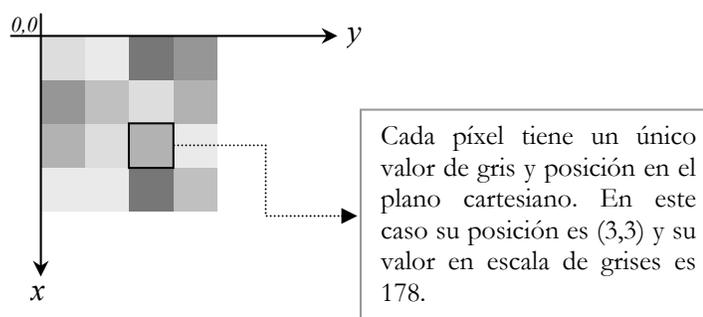


FIGURA 3.1 Píxeles en el plano cartesiano

Los filtros de imágenes digitales utilizan la posición y valor de cada píxel para operarlos de acuerdo a alguna función o procedimiento. Por lo tanto, se puede procesar cada imagen utilizando la información de sus píxeles y realizar un conjunto de procesos morfológicos, lineales, no lineales, pasa banda, etc.

### 3.2 DETECCIÓN DE FALLAS UTILIZANDO TEXTURAS

Una de las variantes importantes para la segmentación, consiste en la detección de fallas a través del análisis de texturas (Mery & Berti, 2003). En este estudio, los autores han utilizado la matriz de co-ocurrencia y la función Gabor para la extracción de características, y un clasificador polinomial, de Mahalanobis y de vecinos cercanos para analizar las características de las texturas, de esta forma se determina el rendimiento de la clasificación utilizando las curvas ROC.

En la figura 3.2 se presenta el esquema de reconocimiento de patrones utilizado. Este consiste en la segmentación de la imagen, extracción de características y clasificación. En cuanto a la segmentación, se ha utilizado el filtro LoG. Esta técnica permite determinar los cambios en las intensidades de gris, de esta manera, se detectan los bordes que contienen las regiones con “fallas hipotéticas”. Este proceso requiere de un análisis de cada una de las zonas donde se encuentre la falla hipotética. Para realizar esto, el esquema de reconocimiento utiliza ventanas de un tamaño

predeterminado, en donde se analiza las regiones cerradas, generadas a partir de la función LoG. Luego, el proceso de extracción establece las características de cada región y el clasificador determina su clase. Se ha utilizado un conjunto de operadores tales como: contraste, promedio, momentos angulares, entropía, coeficiente de correlación, etc., los cuales permiten determinar las principales características de las fallas. La elección de estos métodos ha sido el resultado de los últimos 15 años de investigación.

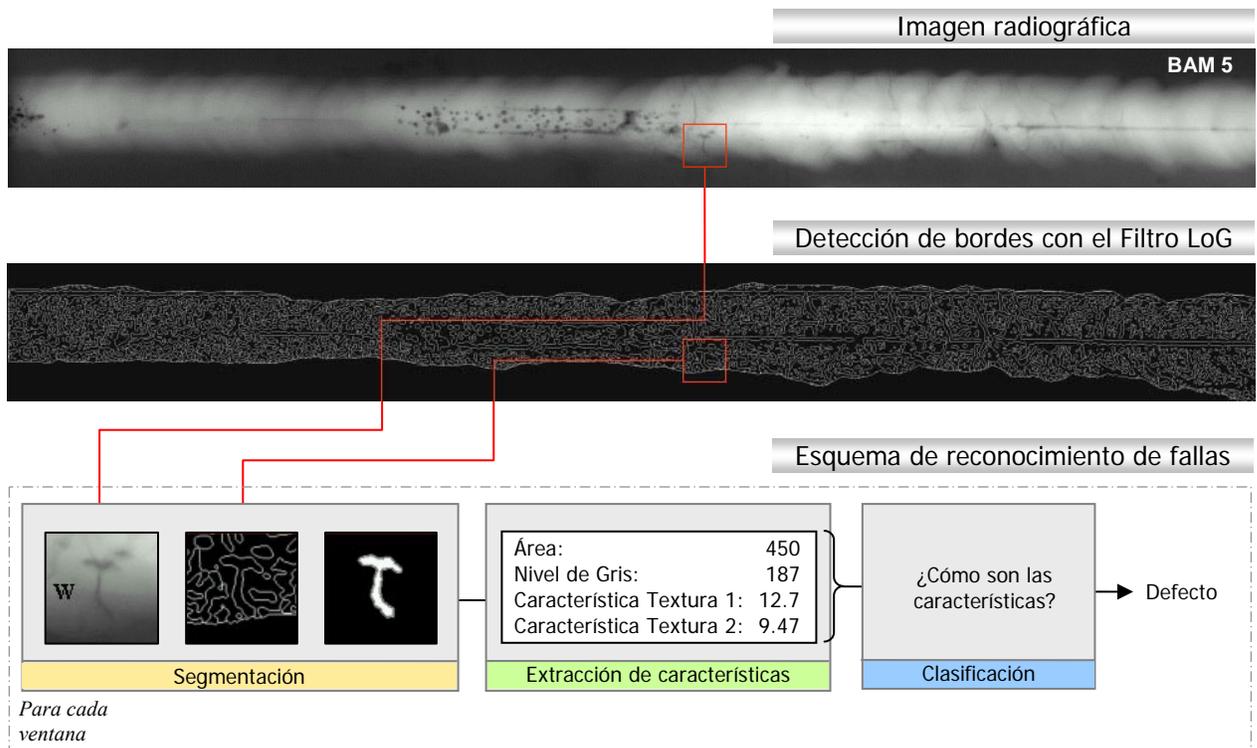


FIGURA 3.2 Sección de BAM-5 con fallas en la soldadura (Mery & Berti, 2003)

Para determinar la curva ROC, se analizan todas las regiones con fallas hipotéticas respecto a una imagen que contiene las fallas reales, esta última realizada a base de una inspección manual. La comparación se realiza en cada región encontrada por el clasificador y la imagen binaria ideal, la cual contiene las fallas reales. Según sus resultados, el clasificador polinomial aplicado a la imagen BAM-5 muestra 90.91% de detección de fallas con 8.11% de falsas alarmas, en cambio el clasificador de Mahalanobis, presenta 90.91% de detección de fallas con 12.69% de falsas alarmas. El clasificador de vecinos cercanos presenta el peor resultado con 79.29% de detección de fallas con 13.75% de falsas alarmas.

### 3.3 TÉCNICAS DE REDUCCIÓN DEL RUIDO

Las imágenes digitales son propensas a tener una variedad de tipos de ruido. Existen varias formas en que el ruido es introducido, dependiendo de cómo es creada la imagen, por ejemplo:

- Si la imagen es una fotografía que es capturada por un escáner, el papel de la fotografía es una fuente de ruido. El ruido puede ser el resultado de daño en el papel, o puede haber sido introducido por el mismo escáner.
- Si la imagen es tomada directamente de un formato digital, el mecanismo de captura de datos (tal como un detector CCD) puede introducir el ruido.
- La transmisión electrónica de los datos de la imagen puede introducir ruido.
- Inestabilidades en la fuente de emisión de contraste como la fuente de luz.

El objetivo de esta fase consiste en eliminar la mayor cantidad de ruido que sea posible, con el fin de mejorar el proceso de segmentación, no obstante, existen distintos tipos de ruido en una imagen, tales como: ruido Gaussiano, impulsivo, frecuencial y multiplicativo (Escalera, 2001), por lo cual se dificulta la reducción. Aunque existe una gran cantidad de filtros de eliminación del ruido, en este caso se analizan tres técnicas: el filtro promedio, Gaussiano y el filtro de la mediana. Cada filtro tiene por objetivo eliminar de mejor forma algún tipo de ruido, por esta razón, se evalúan específicamente en las imágenes del BAM. Según sus resultados, se selecciona el filtro con mejor rendimiento para este tipo de imágenes. Se espera determinar el filtro que atenúe de mejor forma el ruido, preservando los bordes de las estructuras.

#### **Definición 1.**

El modelo básico para definir el ruido en una imagen digital, está compuesto por ruido del tipo aditivo, aleatorio e independiente.

$$Error(i, j) = G(i, j) - I(i, j) \quad (3.1)$$

De esta forma se define el error en función de la imagen observada  $G(i, j)$  afectada por el ruido, menos la imagen original  $I(i, j)$ , siendo los puntos  $i, j$  coordenadas de la imagen.

### 3.3.1 Filtro promedio

El filtro promedio pertenece a la clase de los filtros lineales. La aplicación de este filtro obtiene el promedio de los píxeles que se encuentren contenidos en el tamaño de la máscara ( $m \times m$ ), centrada en la posición  $(i, j)$ . Los valores de la matriz de pesos  $W$  tienen valor 1 y utilizan generalmente máscaras de  $3 \times 3$  ó  $5 \times 5$ . Este filtro se aplica a través del operador de la convolución sobre los píxeles de la imagen  $I$  (González, 1992).

$$S_{(i,j)} = \frac{1}{m^2} \sum_{k=0}^{m-1} \sum_{l=0}^{m-1} w_{(k,l)} \cdot i_{(i+k-1,j+l-1)} \quad \text{donde } w_{k,l} = 1 \text{ y } \forall k,l = 0, \dots, m-1 \quad (3.2)$$

La salida  $S_{(i,j)}$  es el promedio de todos los píxeles vecinos a la posición  $(i, j)$ , incluyendo el píxel central. De este modo, la variación de los niveles de gris disminuye debido al promedio de los píxeles, causando un efecto de suavizado en la imagen. La figura 3.3 muestra la aplicación del filtro promedio. Se observa que no se ha eliminado el ruido, sólo se ha suavizado, además los bordes de los objetos han perdido su definición y contraste, dificultando el posterior proceso de segmentación.

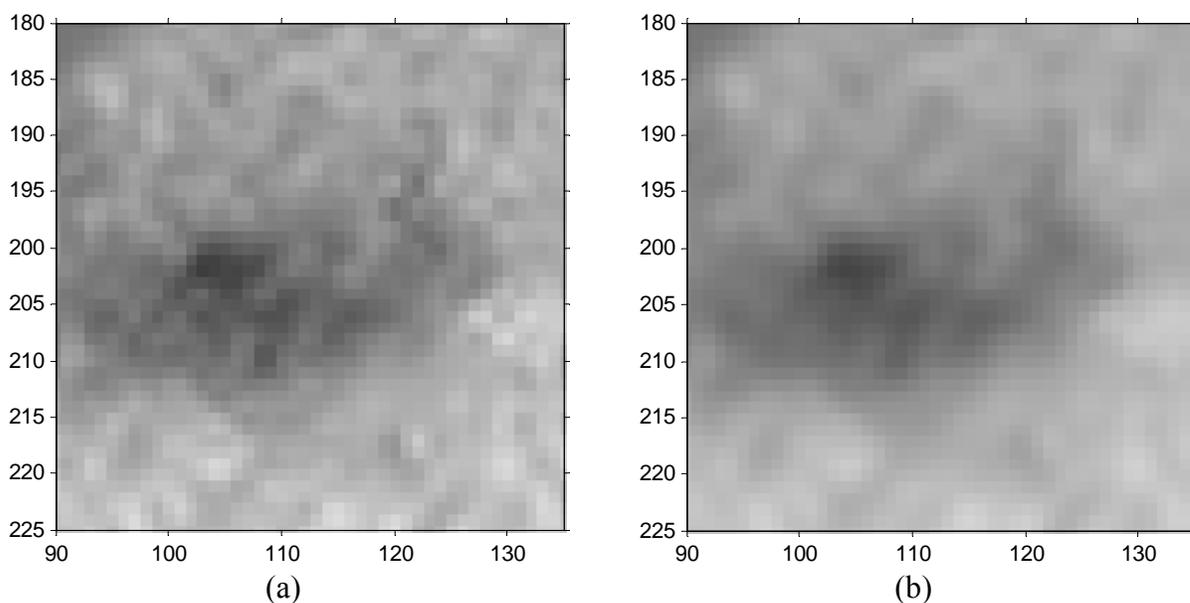


FIGURA 3.3 (a) Imagen original, (b) Aplicación del filtro promedio con máscara de  $3 \times 3$

### 3.3.2 Filtro Gaussiano

El filtro Gaussiano al igual que el filtro promedio, pertenece a la clase de los filtros lineales pasa bajos. Es utilizado para remover ruidos y detalles, además de suavizar la imagen. Para aplicarlo es necesario generar un núcleo Gaussiano, el cual es convolucionado con la imagen original. El grado de curvatura se calcula a partir de la desviación estándar  $\sigma$  (Castleman, 1996).

$$w_{(i,j)} = \frac{1}{2\pi\sigma^2} \cdot e^{\left(-\frac{i^2+j^2}{2\sigma^2}\right)} \quad (3.3)$$

En la figura 3.4 se presenta un ejemplo de la función gaussiana generada a partir de los pesos  $w_{(i,j)}$ . Mientras el valor  $\sigma$  se aproxima a cero, la curva tiende a ser más fina, esto significa que no hay alteración en la imagen original. En cambio, cuando el valor de  $\sigma$  aumenta, la curvatura se ensancha, produciendo un efecto de suavizado en la imagen.

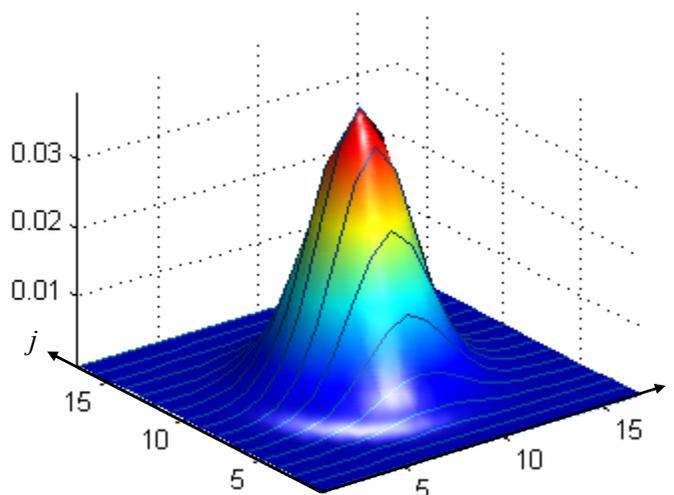


FIGURA 3.4 Representación tridimensional del operador Gaussiano de  $17 \times 17$  y  $\sigma = 2$

La figura 3.5 presenta la aplicación del filtro Gaussiano, se aprecia claramente la pérdida de los bordes de la estructura además de la difusión del fondo de la falla.

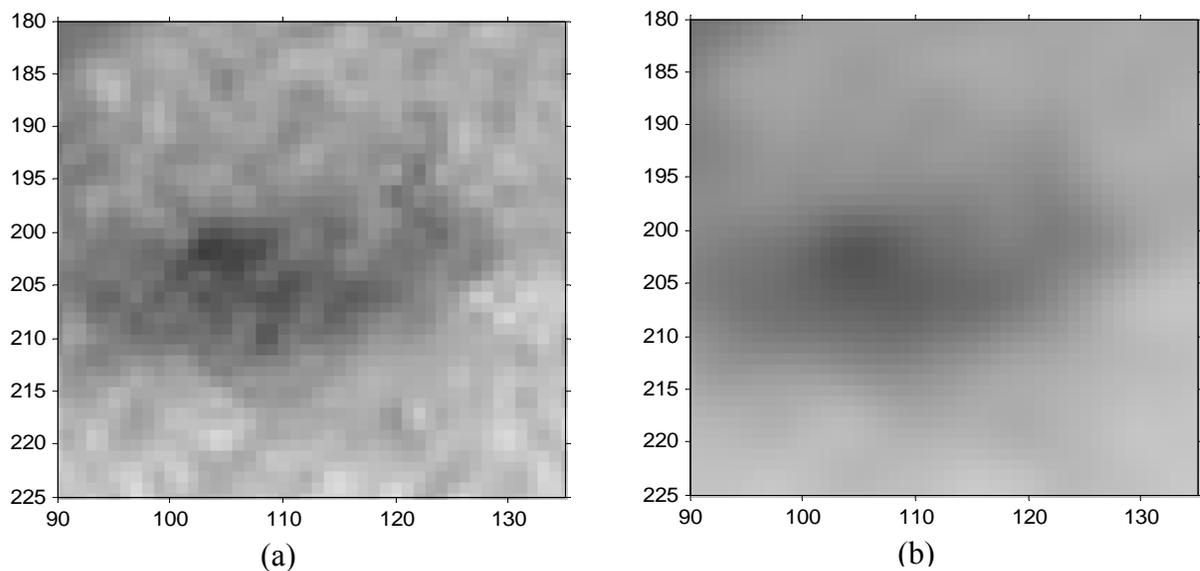


FIGURA 3.5 (a) Imagen original, (b) Aplicación del filtro Gaussiano de  $17 \times 17$  y  $\sigma = 2$

### 3.3.3 Filtro de la mediana

El filtro de la mediana pertenece a la rama de los filtros no lineales, dado que no puede ser modelado por una convolución. Este filtro reemplaza cada píxel de la imagen por el valor de la mediana, calculada a partir de los valores de la máscara que lo rodea, incluyendo el píxel central. El tamaño de la máscara en general es un número impar. La mediana es calculada, ordenando todos los valores de los píxeles que la máscara separa y luego reemplaza el píxel que es considerado como el valor del medio de la lista. Si los vecinos considerados contienen un número par de píxeles, se calcula el promedio de los píxeles del medio de la lista (Castleman, 1996).

La figura 3.6 muestra un ejemplo del cálculo del filtro de la mediana, centrada en el píxel (3,3) de valor 200. Como se observa, el píxel central no es representativo respecto a sus vecinos y es reemplazado por el valor del medio de la lista (121). Este valor fue calculado utilizando una máscara de  $3 \times 3$ , máscaras más grandes producen mayor suavizado.

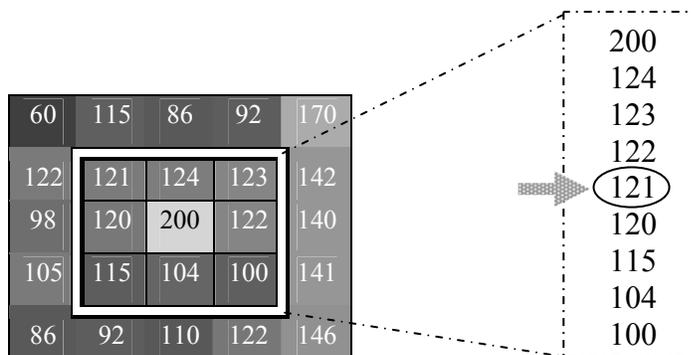


FIGURA 3.6 Cálculo de valor de la mediana para una máscara de 3x3

La figura 3.7 presenta la aplicación del filtro de la mediana sobre la figura 3.7b; en este caso, no existe una pérdida de los bordes. Las estructuras se han mantenido y gran parte del ruido se ha reducido, generando un conjunto de niveles de gris más uniforme.

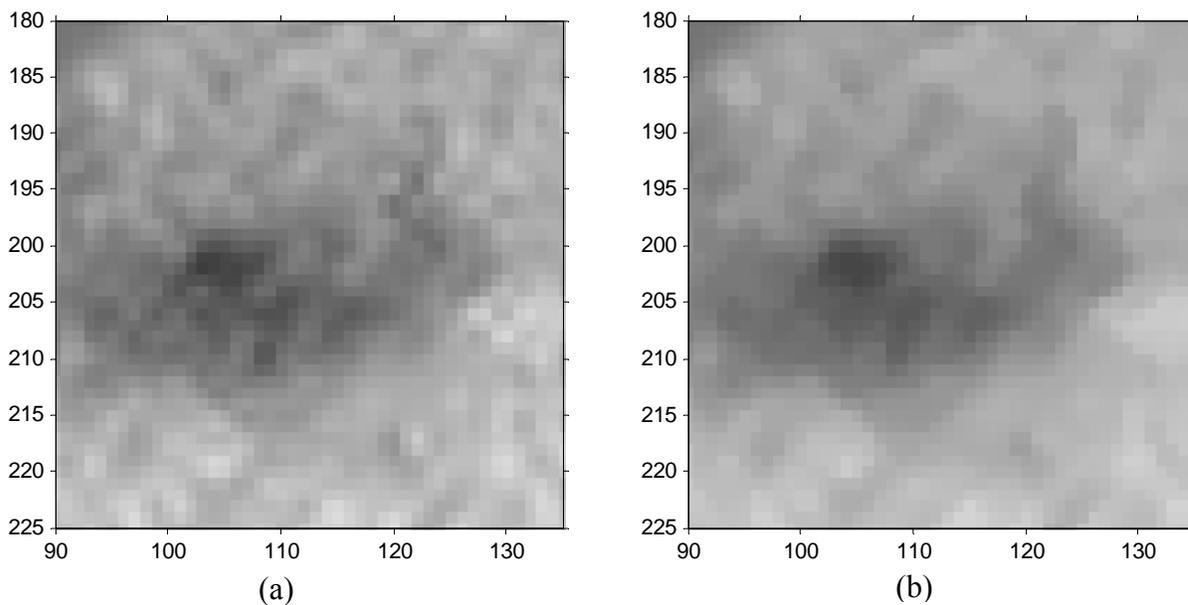


FIGURA 3.7 (a) Imagen original, (b) Aplicación del filtro de la mediana con máscara de 3x3

El uso de la mediana con respecto al filtro promedio tiene dos grandes ventajas. La mediana es un indicador más robusto que el promedio ya que un píxel no representativo no introduce su valor en el resultado. Además la mediana no crea nuevos valores de los píxeles cuando trabaja en los

bordes. Es por esta razón que el filtro de la mediana es mucho mejor para preservar los bordes claramente que el filtro promedio. En comparación con el filtro Gaussiano, la mediana es superior ya que mantiene los bordes de las estructuras; la importancia de esto se debe a la posterior aplicación de los procesos de segmentación.

Otras líneas de investigación han mostrado la ventaja que tiene utilizar el filtro de la mediana, como por ejemplo en la detección de fallas en botellas de vidrio (Medina & Mery, 2003). En este caso se utiliza el filtro de la mediana para generar una imagen “libre de fallas”. Para esto se debe subdividir la imagen en distintas partes y luego aplicar al filtro de la mediana adaptada a cada subimagen. Luego se calcula la diferencia entre la imagen original y la imagen “libre de fallas” y, de esta manera, se obtiene la posición de la falla en el caso que exista una diferencia entre las dos imágenes.

### **3.4 MATEMÁTICA MORFOLÓGICA**

El campo de la matemática morfológica permite realizar un amplio rango de operaciones sobre el procesamiento de las imágenes basado en un conjunto de conceptos matemáticos (González, 1992). Fue desarrollado por Matheron y Serra en la década de los sesenta, y se basó en las estructuras geométricas de los cuerpos y también en su forma. Los operadores morfológicos son muy útiles ya que permiten realizar funciones complejas a partir de la combinación de sus operadores. De este modo, se pueden realizar diferentes análisis en imágenes binarias y en escalas de grises, los cuales son utilizados comúnmente para la reducción del ruido, realce de la imagen, detección de bordes y segmentación.

Las dos operaciones básicas en la matemática morfológica son la erosión y la dilatación. Estos operadores toman dos entradas, la imagen a erosionar o a dilatar y su estructura. Es importante notar que la erosión y la dilatación no son inversas, de hecho dilatar y luego erosionar raramente se transforma en la misma imagen.

### 3.4.1 Erosión

La erosión es uno de los operadores básicos en el área de la matemática morfológica. El efecto de este operador en una imagen de escala de grises consiste en contraer las cimas positivas, mientras los valores negativos son expandidos; debido a esto, la imagen generalmente se oscurece. Las regiones claras, rodeadas de regiones oscuras se encogen, por el contrario, las regiones oscuras rodeadas de regiones claras crecen en tamaño. Los píxeles claros rodeados de zonas oscuras desaparecen, esto permite eliminar la mayoría del ruido anexado en la imagen, en cambio los píxeles oscuros rodeados de zonas claras, crecen. Los efectos son marcados en las zonas en donde existe un cambio brusco en la intensidad.

La figura 3.8 muestra un corte longitudinal de los niveles de gris de una imagen, las cimas son los puntos más claros y los valles son las regiones más oscuras.

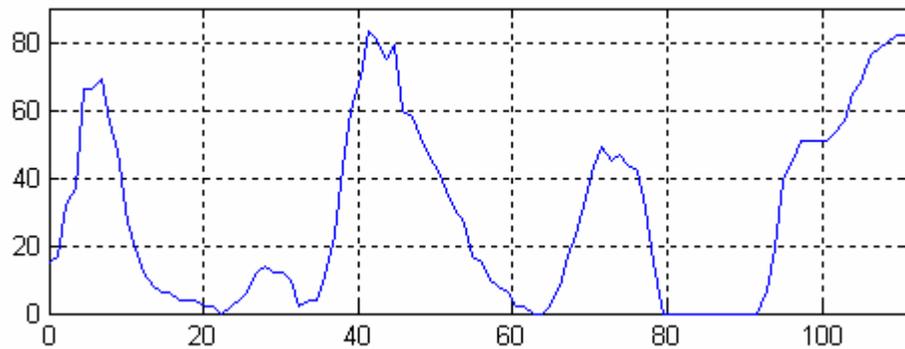


FIGURA 3.8 Corte longitudinal de una imagen y su nivel de gris

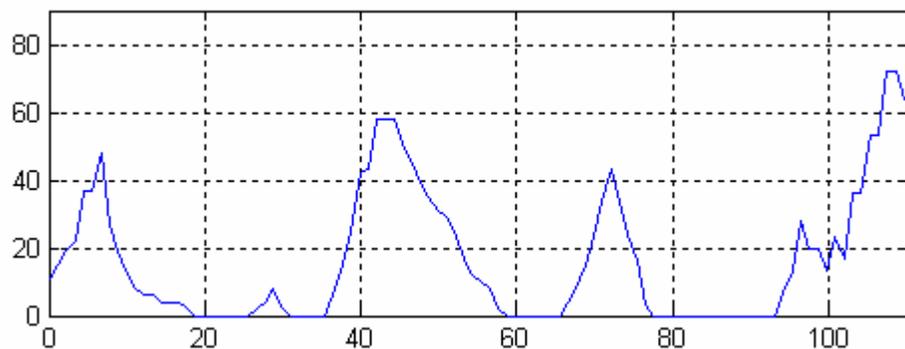


FIGURA 3.9 Aplicación del operador de erosión a la señal de la figura 3.8

En la figura 3.9 se observa que las cimas han disminuido su magnitud, los valles se hacen más planos y aumentan en tamaño, además el nivel de intensidad de gris se ha reducido haciendo que la imagen resultante sea más oscura que la original y con menos detalles.

Matemáticamente, la erosión se define como:

$$E(A, B) = A \ominus B = \bigcap_{b \in B} (A - b) \quad (3.4)$$

La interpretación geométrica se puede ver en la figura 3.10, donde A es la imagen y B es la máscara. La idea básica es imaginar que el círculo B rueda alrededor de A, suavizando sus bordes externos. Hay que notar que es el centro de B el que rueda en el borde interno de A.

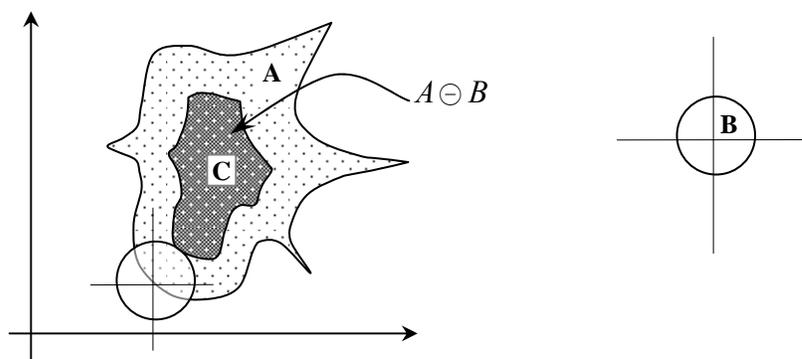


FIGURA 3.10 Representación gráfica del operador de la erosión

La región interna C (figura 3.10) es el resultado de la operación  $(A \ominus B)$ . La figura 3.11a representa la imagen original (A), y la figura 3.11b muestra la aplicación de la erosión utilizando una estructura de disco B.

En una imagen binaria la erosión produce una disminución del ruido, ya que los píxeles inferiores al tamaño de la máscara son eliminados. Si los píxeles de B no son contenidos en la región A, estos últimos desaparecen, dado que B es trasladado alrededor de A. En el caso de la figura 3.11 la mayoría del ruido ha sido eliminada, permaneciendo una estructura con una menor cantidad de regiones.

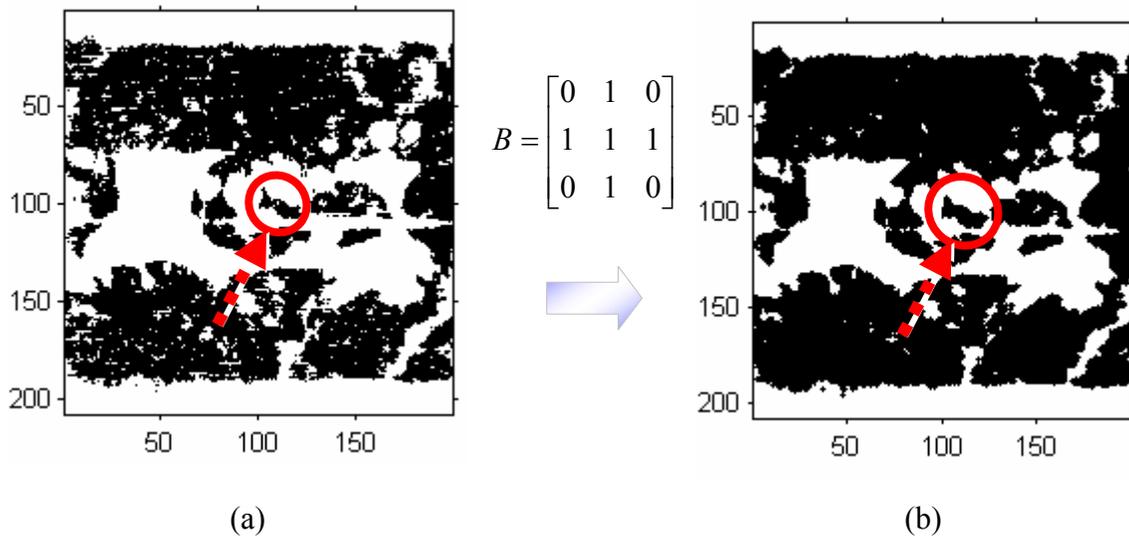


FIGURA 3.11 (a) Imagen original binaria, (b) Aplicación de la erosión sobre (a)

### 3.4.2 Dilatación

La dilatación es otra función muy utilizada por la mayoría de las operaciones morfológicas. Su efecto sobre una imagen de escala de grises consiste en expandir los valores positivos, en consecuencia, los puntos positivos se aglomeran junto a otros cuando se encuentran cercanos entre sí. En el caso de estar separados, estos puntos se expanden. Los puntos negativos que se encuentren rodeados de zonas positivas, son agregados a regiones de mayor tamaño. Al igual que la erosión, la dilatación hace uso de una máscara con la cual se realiza el proceso de expansión. Un efecto marcado es que la imagen aumenta su brillo ya que las zonas positivas crecen.

En el caso que el núcleo tenga forma circular, los bordes de los objetos se suavizan, esto se debe a que los bordes tienen una diferencia marcada en los niveles de intensidad, la expansión de estos hace que la imagen pierda definición.

En la figura 3.12 se muestra un corte longitudinal de una imagen en escala de grises. Las cimas son los puntos más claros y los valles son las regiones más oscuras; en la figura 3.13 se muestra la aplicación de la dilatación sobre la figura 3.12.

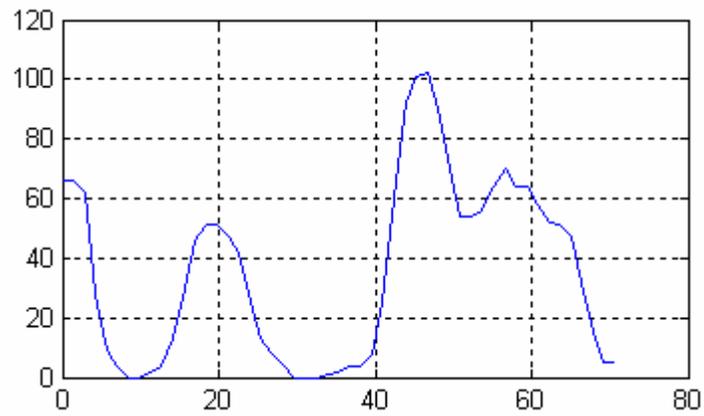


FIGURA 3.12 Corte longitudinal de una imagen

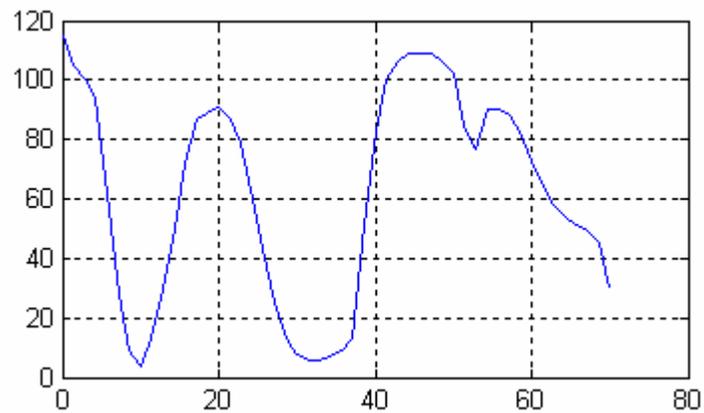


FIGURA 3.13 Aplicación de la dilatación a la señal de la figura 3.12

La interpretación geométrica se puede ver en la figura 3.14. En este caso las pequeñas entradas y cortes que tiene A son suavizados. Una aplicación práctica de la dilatación es substraerla a la imagen original, quedando como resultados los bordes de la figura.

En forma matemática la dilatación queda expresada como:

$$D(A,B) = A \oplus B = \bigcup_{b \in B} (A + b) \quad (3.5)$$

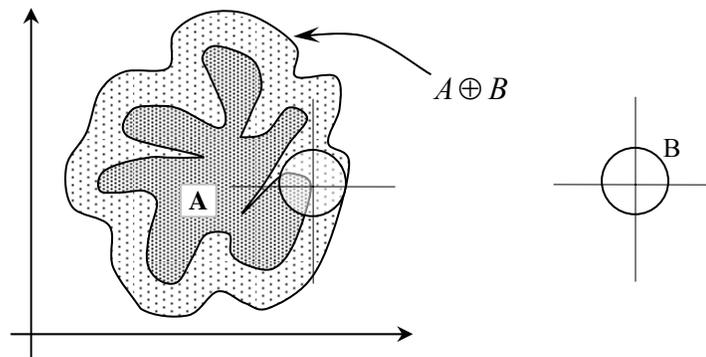


FIGURA 3.14 Representación gráfica del operador de dilatación

En la dilatación binaria, los elementos unitarios de A son expandidos utilizando la máscara B, que rueda alrededor de A. Se aprecia que las regiones positivas se han expandido y además, cualquier píxel de la figura 3.15a que se encuentre rodeado de un área negativa, es rellenado por la estructura B. Un ejemplo de esto se indica con las flechas de la figura 3.15. En la figura 3.15b las regiones blancas han aumentado en tamaño y forma; algunas de estas estructuras se han unido a otras, quedando regiones completamente unidas y perdiéndose la información de los límites de las regiones.

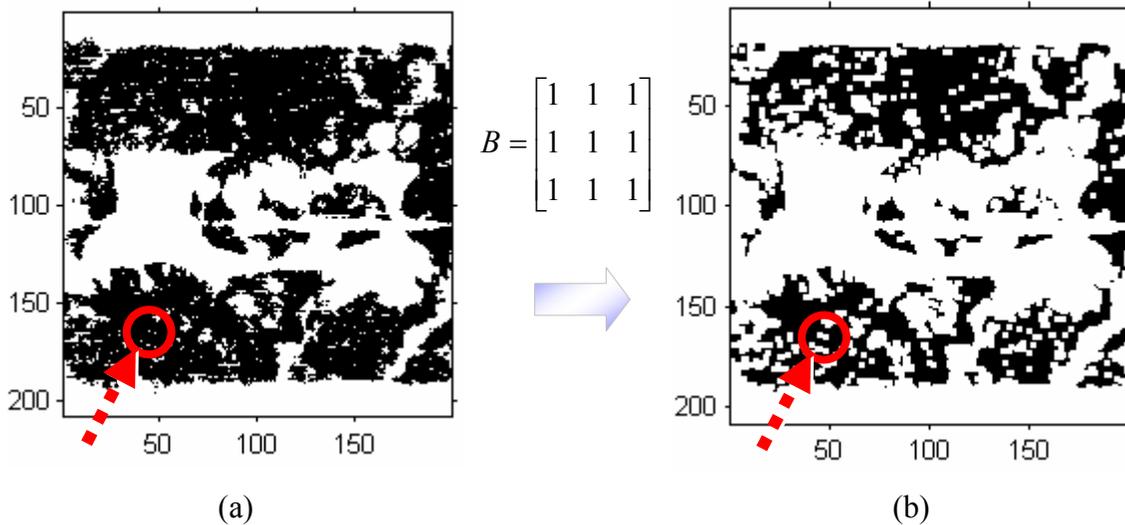


FIGURA 3.15 (a) Imagen original binaria, (b) Aplicación de la dilatación sobre (a)

### 3.4.3 Apertura

La apertura es una función que consiste de dos etapas, primero se aplica la erosión, y luego la dilatación. Esta operación utiliza una misma máscara para las dos operaciones anteriores. Su uso permite eliminar detalles u objetos pequeños (tales como el ruido), esto simplifica la imagen, además de separar objetos adyacentes.

La apertura se define en función de las operaciones de erosión y luego dilatación:

$$\text{Apertura}(A, B) = A \circ B = \text{Dilatación}(\text{Erosión}(A, B), B) = (A \ominus B) \oplus B \quad (3.6)$$

La apertura es utilizada para remover o atenuar los valores positivos de la imagen. En la práctica elimina los detalles que existan, claramente esto reduce el brillo ya que al aplicar la erosión una gran cantidad de píxeles positivos han desaparecido. Luego, al aplicar la dilatación sólo se pueden dilatar los píxeles positivos que han permanecido, esto rellena los orificios negativos, por lo tanto, la imagen pierde detalles y tiene una mayor cantidad de zonas planas. En la figura 3.16b, se aprecia como se ha eliminado el ruido de la figura 3.16a.

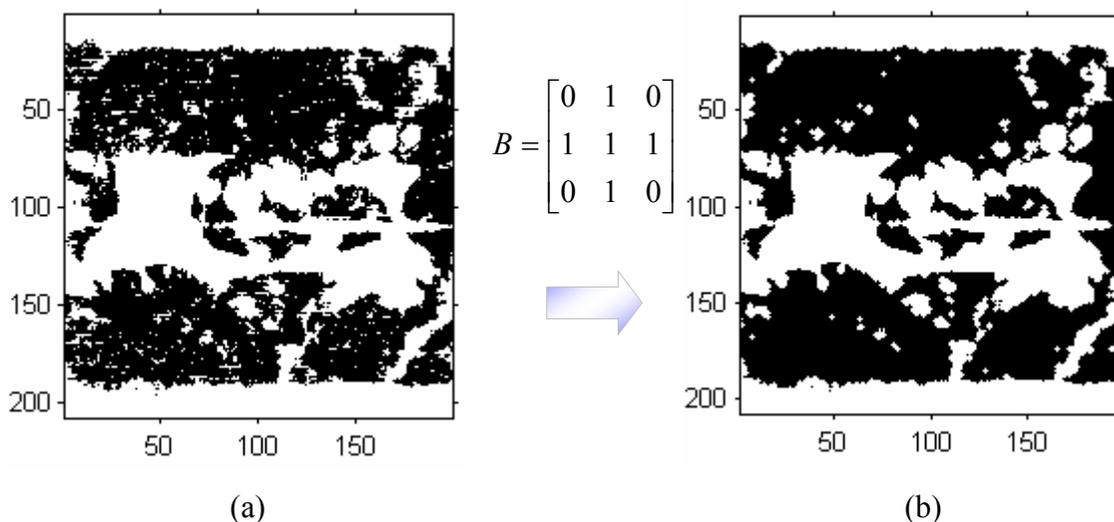


FIGURA 3.16 (a) Imagen original binaria, (b) Aplicación de la apertura sobre (a)

### 3.4.4 Cerradura

La cerradura es una función que tiene dos pasos, primero se aplica la dilatación, y luego se aplica la erosión. Al aplicar la dilatación, se rellenan los orificios o los píxeles que están rodeados de áreas positivas. Luego al aplicar la erosión se suavizan los bordes de los objetos, sin embargo, no es útil para eliminar el ruido ya que con la dilatación estos píxeles se expanden, y el operador de la erosión no puede removerlos.

La cerradura se define en función de las operaciones de dilatación y luego la erosión:

$$Cerradura(A, B) = A \bullet B = Erosión(Dilatación(A, B), B) = (A \oplus B) \ominus B \quad (3.7)$$

Su principal uso es conectar objetos, ya que la dilatación al engrosar los bordes une objetos que están separados, además permite rellenar los orificios no llenados. En la figura 3.17b se observa que se han suavizado los bordes. En el caso de imágenes en escalas de grises, estas aumentan su brillo ya que la aplicación de la dilatación aumenta el nivel de los píxeles positivos además de unir regiones.

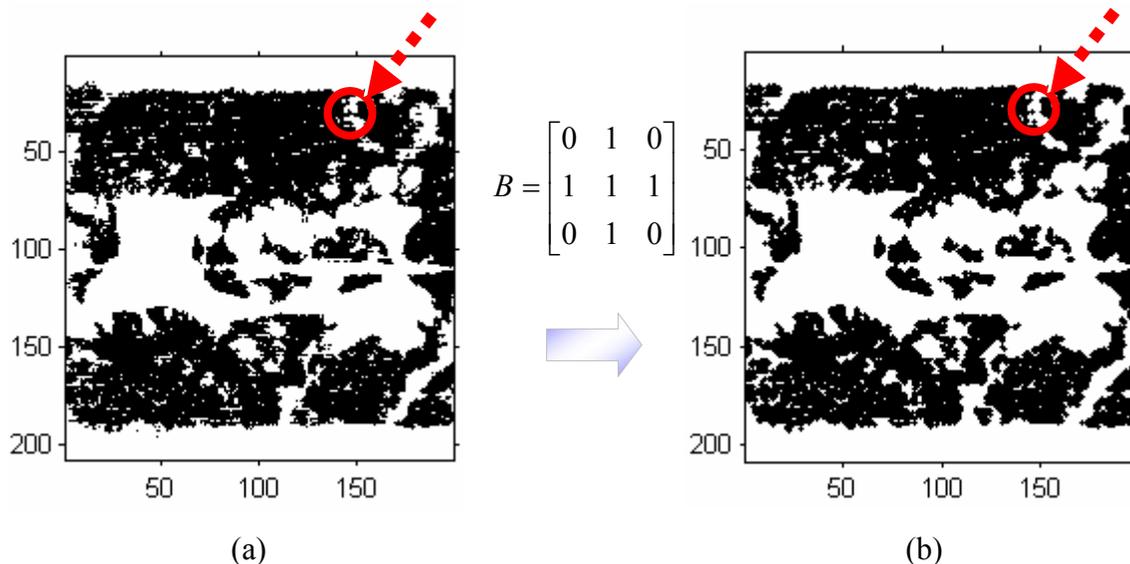


FIGURA 3.17 (a) Imagen original binaria, (b) Aplicación de la cerradura sobre (a)

Al aplicar la erosión, las regiones que antes eran disjuntas o las áreas no rellenas, no pueden volver al mismo estado, ya que la dilatación las ha unido. Por lo tanto, los niveles positivos son mayores que la original, por esta razón aumenta el brillo.

### 3.4.5 Detección morfológico de bordes

A partir de las operaciones de dilatación y erosión se pueden detectar los bordes a través de:

$$L = A \cap (A \ominus B)^c \quad (3.8)$$

Que es lo mismo que :

$$L = (A) \text{ AND } (\text{NOT}(\text{EROSION}(A, B))) \quad (3.9)$$

Aún cuando esta detección de bordes es eficiente para el caso binario, se puede ver experimentalmente que existe en la imagen una gran cantidad de ruido que no ha sido eliminada. El ruido sobrante en la imagen resultante, es producto de la intersección entre la imagen  $A$  y  $(A \ominus B)^c$ ; esto se debe a que la imagen  $A$  tiene una gran cantidad de ruido (figura 3.18).

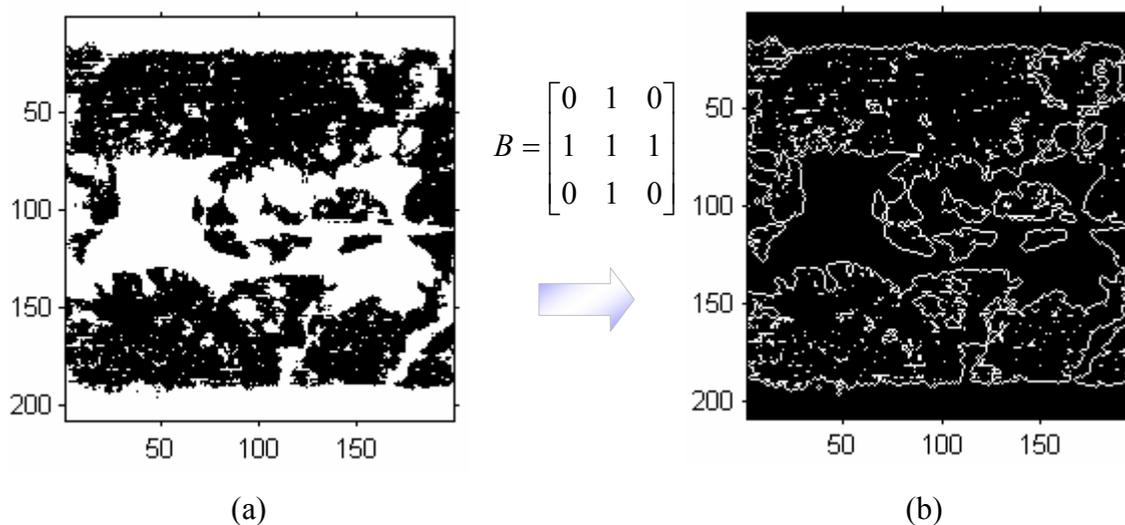


FIGURA 3.18 (a) Imagen original binaria, (b) Detector morfológico de bordes sobre (a)

Para eliminar el ruido, una de las opciones es aplicar primero una apertura a la imagen  $A$ , lo cual elimina mucho del ruido existente. Por lo tanto, sea  $P$  el resultado de la apertura de la imagen  $A$  con una máscara  $B$ :

$$P = (A \ominus B) \oplus B \quad (3.10)$$

$P$  equivale a la apertura  $(A, B)$ , esta operación elimina gran parte del ruido existente. Para marcar sólo los bordes de las figuras y con una baja cantidad de ruido, la opción es rellenar los orificios de la imagen  $P$ . Si se aplica el resultado  $P$  en la detección de bordes y se reemplaza la variable  $A$  en la ecuación 3.8, se tiene que:

$$L' = P \cap (P \ominus B)^c \quad (3.11)$$

Desarrollando los términos se puede formar un detector de bordes con una baja cantidad de ruido reemplazando la variable  $P$  de la ecuación 3.10 en la ecuación 3.11, como:

$$L' = ((A \ominus B) \oplus B) \cap (((A \ominus B) \oplus B) \ominus B)^c \quad (3.12)$$

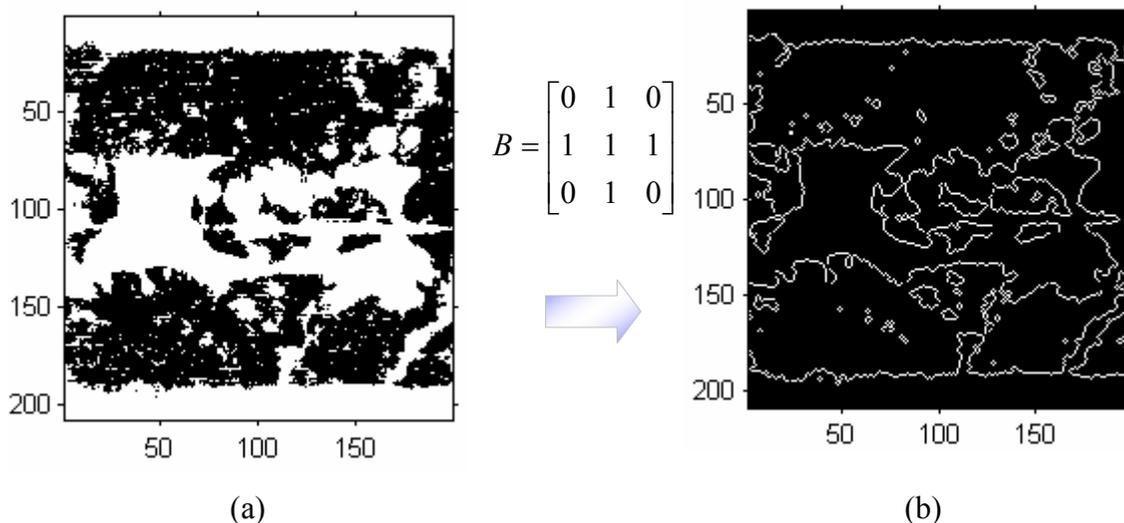


FIGURA 3.19 (a) Imagen original binaria, (b) Detector morfológico de bordes con eliminación del ruido sobre (a)

### 3.5 TÉCNICAS DE SEGMENTACIÓN

La segmentación consiste en la partición de la imagen en regiones disjuntas, en la cual, cada región es homogénea respecto a alguna propiedad, pudiendo ser la textura, nivel de gris, color, etc., con el objeto de separar las regiones de interés para su posterior reconocimiento (González, 1992). De este modo, el problema de segmentación puede ser atacado por distintos métodos, en líneas generales se puede categorizar en tres tipos de técnicas: orientadas a la detección de bordes, detección del píxel y detección de regiones (Mery, 2002).

En las estrategias de detección de bordes que se analizan, están los filtros que utilizan el gradiente, en esta categoría se encuentra el filtro de Roberts, Prewitt, Sobel y Laplaciano de la Gaussiana (Castleman, 1996). Estos calculan el gradiente y de acuerdo a un nivel del umbral, determinan que existe un posible borde. El filtro de Canny (Canny, 1986), utiliza una combinación de técnicas, tales como el filtro Gaussiano para la reducción del ruido y también el uso de gradientes direccionales, permitiendo seleccionar sólo los bordes que se encuentren en el umbral especificado. Dentro de la detección de píxeles, se encuentra la umbralización. Esta técnica es una de las más extendidas ya que permite convertir una imagen en niveles de gris o en color, en una imagen binaria. De este modo, permite separar objetos de su fondo de acuerdo a cierto nivel del umbral. En la detección de regiones, se encuentra la transformada de Watershed (Beucher et al, 1979); esta técnica hace uso de la matemática morfológica, permitiendo generar regiones a partir del llenado de cavidades, simulando que se vierte agua en un valle. A medida que el nivel del agua sube, se van llenando las cavidades formando diques con las regiones adyacentes. Finalmente, se estudia la transformada de la distancia y el modo con el cual puede influir en la transformada de Watershed para generar una mejor definición en el tipo de segmentación.

En este caso, la segmentación se utiliza con el propósito de separar regiones conocidas como “fallas hipotéticas”. Estas regiones están constituidas por fallas verdaderas y falsas alarmas, siendo tarea de un clasificador separar correctamente estos grupos de acuerdo a un conjunto de propiedades geométricas, tales como: área, perímetro, momentos invariantes, etc., que son analizadas en el proceso de extracción de características (Mery & Filbert, 2002).

Muchas veces la segmentación genera un gran conjunto de regiones, lo cual requiere un mayor tiempo en procesamiento y cálculo para cada región, afectando al proceso general de la AVI. Por este motivo, es importante que la segmentación genere un bajo número de regiones, y que sean en mayor grado fallas verdaderas, minimizando las falsas alarmas. Este requerimiento hace necesario un estudio de distintas técnicas de segmentación, el cual permita generar regiones con mayor precisión y en menor cantidad.

### 3.5.1 Gradiente

El gradiente es un vector que apunta a la dirección de mayor cambio y su magnitud representa la razón de cambio (González, 1992). En el caso de las imágenes digitales, el resultado del gradiente denota las zonas y bordes donde existe un cambio de tonalidad o umbral. Al aplicar el gradiente a la figura 3.20, el operador delimita las fronteras de las zonas con mayor cambio de tonalidad, quedando como resultado sólo los bordes de las fallas hipotéticas.

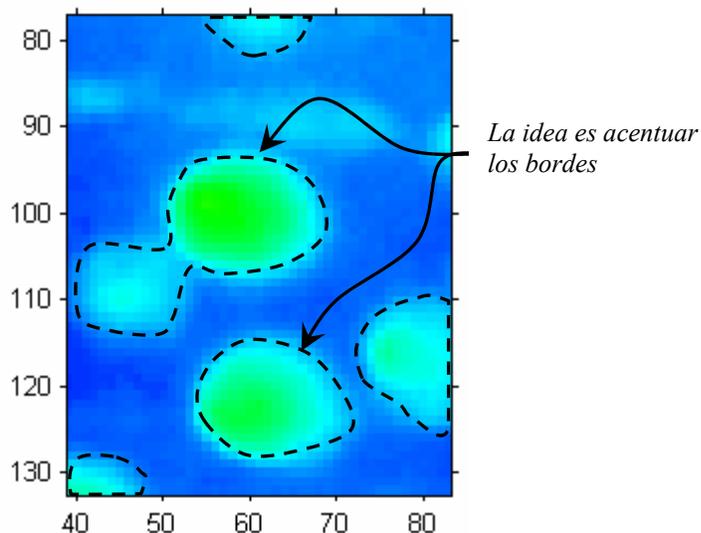


FIGURA 3.20 Aplicación del gradiente en la detección de bordes

La imagen de la figura 3.20 presenta una escala de pseudocolor para resaltar los bordes, de este modo, se facilita la visualización de las fallas debido a la diferencia de color con respecto a su fondo.

Existen diferentes aproximaciones para evaluar el gradiente, no obstante, este cálculo se ha facilitado debido al uso de plantillas, dado que el muestreo es regular. Matemáticamente el gradiente se define como el vector de derivadas parciales de sus operadores:

$$G\{f(i, j)\} = \begin{bmatrix} \frac{\partial f(i, j)}{\partial i} \\ \frac{\partial f(i, j)}{\partial j} \end{bmatrix} \quad (3.13)$$

El módulo del gradiente se define como:

$$|G\{f(i, j)\}| = \sqrt{\left(\frac{\partial f}{\partial i}\right)^2 + \left(\frac{\partial f}{\partial j}\right)^2} \quad (3.14)$$

Aproximando digitalmente las derivadas parciales del gradiente y desarrollando los términos, se obtiene:

$$\begin{aligned} \left(\frac{\partial f(i, j)}{\partial i}\right)^2 &\cong (f(i, j) - f(i, j+1))^2 \\ \left(\frac{\partial f(i, j)}{\partial j}\right)^2 &\cong (f(i, j) - f(i+1, j))^2 \end{aligned} \quad (3.15)$$

De esta manera, el gradiente se aproxima digitalmente a la suma y resta de los píxeles vecinos a cada píxel de la imagen original, es decir:

$$|G\{f(i, j)\}| \cong \sqrt{(f(i, j) - f(i, j+1))^2 + (f(i, j) - f(i+1, j))^2} \quad (3.16)$$

Separando los términos, se define una aproximación digital del gradiente:

$$|G\{f(i, j)\}| \cong |f(i, j) - f(i, j+1)| + |f(i, j) - f(i+1, j)| \quad (3.17)$$

### 3.5.2 Gradiente de Roberts:

Este filtro no lineal, es el más simple de los filtros para la detección de bordes. Tiene la desventaja que es muy sensible al ruido debido al reducido tamaño de su máscara y además realza algunos bordes más que otros, dado el desplazamiento de los gradientes. Separando las dos sumas de los valores absolutos, se puede separar dos plantillas matriciales (tabla 3.1)

$$|G\{f(i, j)\}| \cong |f(i, j) - f(i+1, j+1)| + |f(i+1, j) - f(i, j+1)| \tag{3.18}$$

TABLA 3.1 Máscara del gradiente de Roberts

1	0
0	-1

0	-1
1	0

La figura 3.21 presenta una sección de BAM-5 con una escala modificada del color. Experimentalmente, los bordes encontrados han sido en las zonas en donde la variación de tonalidad ha sido mayor; al contrario, en las zonas donde existe una diferencia menor en la tonalidad, el filtro no ha generado dichos bordes.

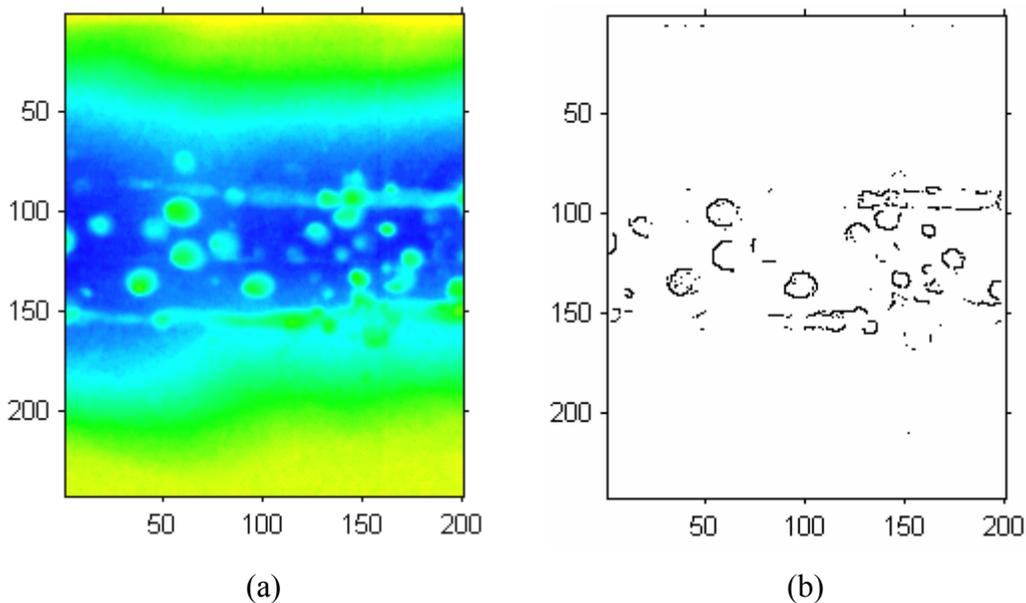


FIGURA 3.21 (a) Imagen original en pseudocolor, (b) Aplicación del gradiente de Roberts

### 3.5.3 Gradiente de Prewitt

Este filtro tiene una plantilla de 3x3, lo cual permite tener una visión retardada y adelantada de los cambios que se realizan sobre los píxeles. Se observa que la suma de cada matriz es cero (tabla 3.2); esto se realiza para evitar que la plantilla introduzca un sesgo en el resultado.

TABLA 3.2 Máscara del gradiente de Prewitt

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

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

La aplicación retardada y adelantada permite que este filtro encuentre una mayor cantidad de bordes, en comparación con el filtro de Roberts. No obstante, se observa en la figura 3.22b que no se han generado todos los bordes de las fallas de la figura 3.22a, además es deficiente en generar bordes cerrados.

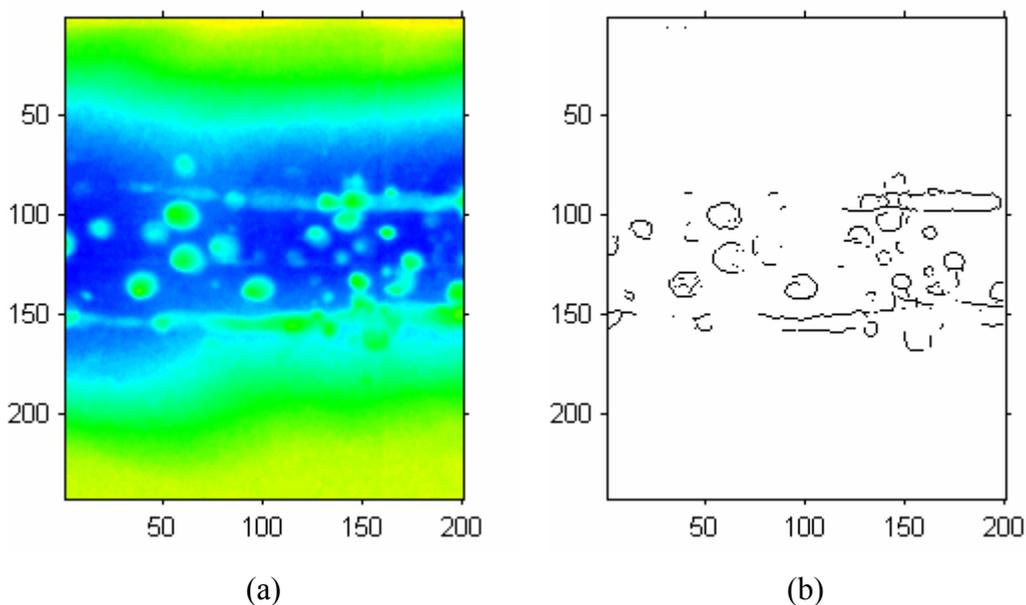


FIGURA 3.22 (a) Imagen original en pseudocolor, (b) Aplicación del gradiente de Prewitt

### 3.5.4 Gradiente de Sobel

Este filtro es el resultado de aplicar la teoría del cuadrado del binomio, en este caso, se pondera la fila y la columna en la cual se calcula el gradiente. La máscara de este filtro es una plantilla de 3x3 (tabla 3.3).

TABLA 3.3 Máscara del gradiente de Sobel

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

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

En la figura 3.23b se muestra el resultado del filtro de Sobel. Se distingue que no existe una mayor diferencia con respecto al resultado generado por el gradiente de Prewitt. Por este motivo, el uso del cuadrado del binomio no ha producido una mejor definición de los bordes, además no se han generado bordes cerrados.

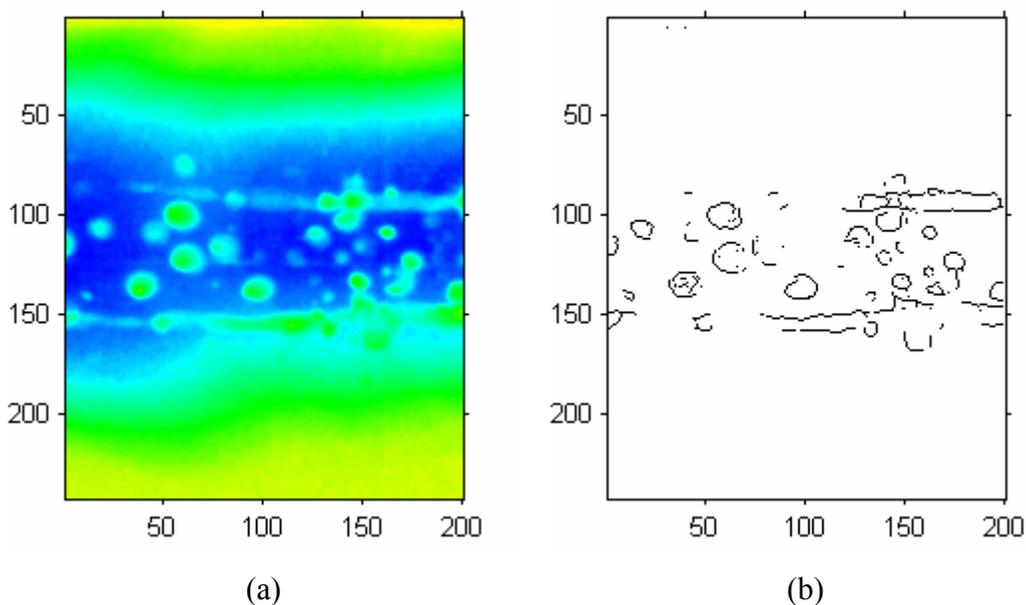


FIGURA 3.23 (a) Imagen original en pseudocolor, (b) Aplicación del gradiente de Sobel

### 3.5.5 Gradiente Laplaciano de la Gaussiana (LoG)

El filtro Laplaciano utiliza la segunda derivada para generar un conjunto de bordes cuando la salida del operador encuentra un cruce por cero, sin embargo, el operador Laplaciano es deficiente para encontrar bordes ya que es muy sensible al ruido (Escalera, 2001). Una forma de evitar este problema es convolucionar la imagen  $I(i, j)$  con el laplaciano de una gaussiana  $\nabla^2 G(i, j)$ . La combinación de las dos técnicas genera un conjunto de bordes más preciso y con menor cantidad de ruido. El filtro se denomina LoG (Laplacian of Gaussian) y su expresión matemática está definida como:

$$\nabla^2 G(i, j) = \nabla^2 \left( \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{i^2+j^2}{2\sigma^2}} \right) = \frac{i^2 + j^2 - 2\sigma^2}{2\pi\sigma^6} e^{-\frac{i^2+j^2}{2\sigma^2}} \quad (3.19)$$

$$LoG(i, j) = (\nabla^2 G(i, j)) * I(i, j)$$

A diferencia de los filtros anteriores, el filtro Laplaciano de la Gaussiana produce una mejor definición de bordes, generando una mayor cantidad y capturando incluso zonas con menor tamaño (figura 3.24), sin embargo, aún persiste el problema de las regiones abiertas.

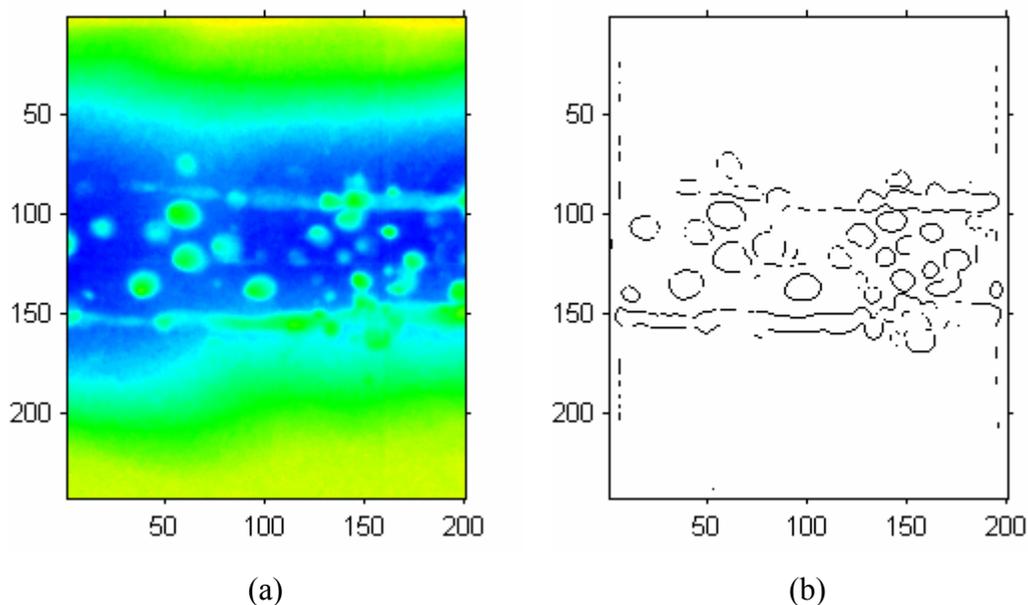


FIGURA 3.24 (a) Imagen original en pseudocolor, (b) Aplicación del gradiente de Laplaciano

Para ello se ha utilizado algunas estrategias para cerrar los bordes y definir las fallas hipotéticas. Una de ellas se presenta en (Mery & Filbert, 2002). La idea consiste en aumentar los bordes donde el cambio en el nivel de intensidad sea mayor, así los bordes que se encuentren cerrados son segmentados y considerados como “fallas hipotéticas”.

### 3.5.6 El método de Canny

En 1986, Canny (Canny, 1986) presentó un algoritmo de detección de bordes. El algoritmo consta de una serie de pasos: Primero, se debe suavizar la imagen mediante un filtro Gaussiano, de esta manera se reduce el ruido, luego se debe convolucionar la imagen utilizando operadores de gradiente direccionales, los cuales son calculados usando el arcotangente del radio de las derivadas. Los píxeles candidatos son identificados a través de un proceso llamado “*supresión de no máximos*”; este análisis calcula la magnitud de cada píxel y lo compara con sus vecinos, para luego dejar los píxeles que son máximos en su contorno. Finalmente, el algoritmo hace uso de dos umbrales que tienen la función de ser el rango en el cual los bordes se encuentran. Este proceso se llama *histéresis*, la idea es conectar los píxeles que se encuentran por debajo del umbral inferior, con los que superan el umbral superior (figura 3.25).

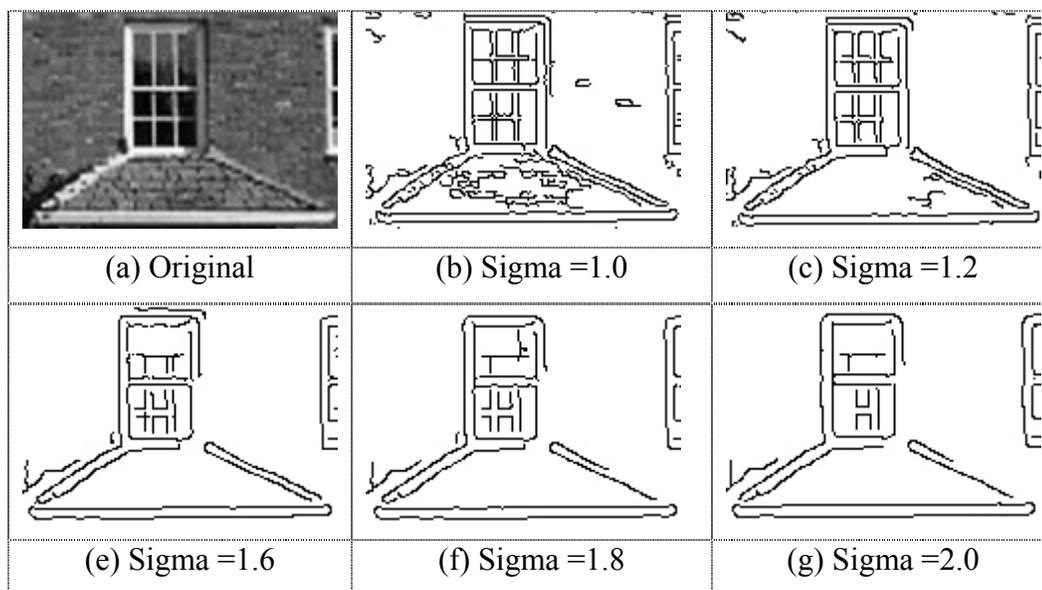


FIGURA 3.25 Uso de filtro de Canny con parámetros  $L=0.4$  y  $H=0.8$  (Li, 2004)

En (Escalera, 2001) se puede encontrar un pseudoalgoritmo para encontrar los bordes a través del filtro de Canny sobre una imagen. El estudio de comparación de (Heath, 1996), demostró que dentro de los distintos tipos de algoritmos de detección de bordes, el filtro de Canny es el algoritmo con mejor rendimiento, sin embargo, los resultados mejoran cuando los parámetros son adaptados a cada imagen.

### 3.5.7 Umbralización

Existen distintos tipos de umbralización, dentro de los cuales se encuentra la umbralización fija, generalizada y adaptativa (Pichel, 2002). La umbralización fija es una de las técnicas más utilizadas en el procesamiento digital de imágenes, ya que permite convertir una imagen en escala de gris o en color, en una imagen binaria, de este modo, se puede separar regiones de interés del fondo de la imagen. En este caso, se requiere determinar un nivel del umbral, de tal manera de separar los niveles superiores e inferiores y binarizarlos.

La figura 3.26 presenta un ejemplo de umbralización fija. A medida que aumenta el valor del umbral, la imagen resultante genera estructuras con menos detalles, en consecuencia, las regiones generadas captan las zonas con mayor nivel de intensidad. Por lo tanto, es importante elegir un valor que capte la mayor cantidad de regiones, tratando de minimizar la mayor cantidad de ruido.

Para el caso de la umbralización fija, la imagen binaria se obtiene mediante:

$$R(i, j) = \begin{cases} 1 & \text{si } I(i, j) \geq U \\ 0 & \text{si } I(i, j) < U \end{cases} \quad (3.20)$$

Donde  $R(i, j)$  se compone a partir de la imagen original  $I(i, j)$  de acuerdo al nivel del umbral  $U$ . En el caso de la umbralización generalizada, se puede determinar un rango en el cual se separa el histograma; esto se puede deber a la imposibilidad de determinar un único valor que separe las regiones, por ejemplo, en imágenes que tengan problemas de iluminación. En este sentido, también es posible determinar valores independientes del umbral, así se cuenta con niveles específicos a los cuales aplicar la umbralización.

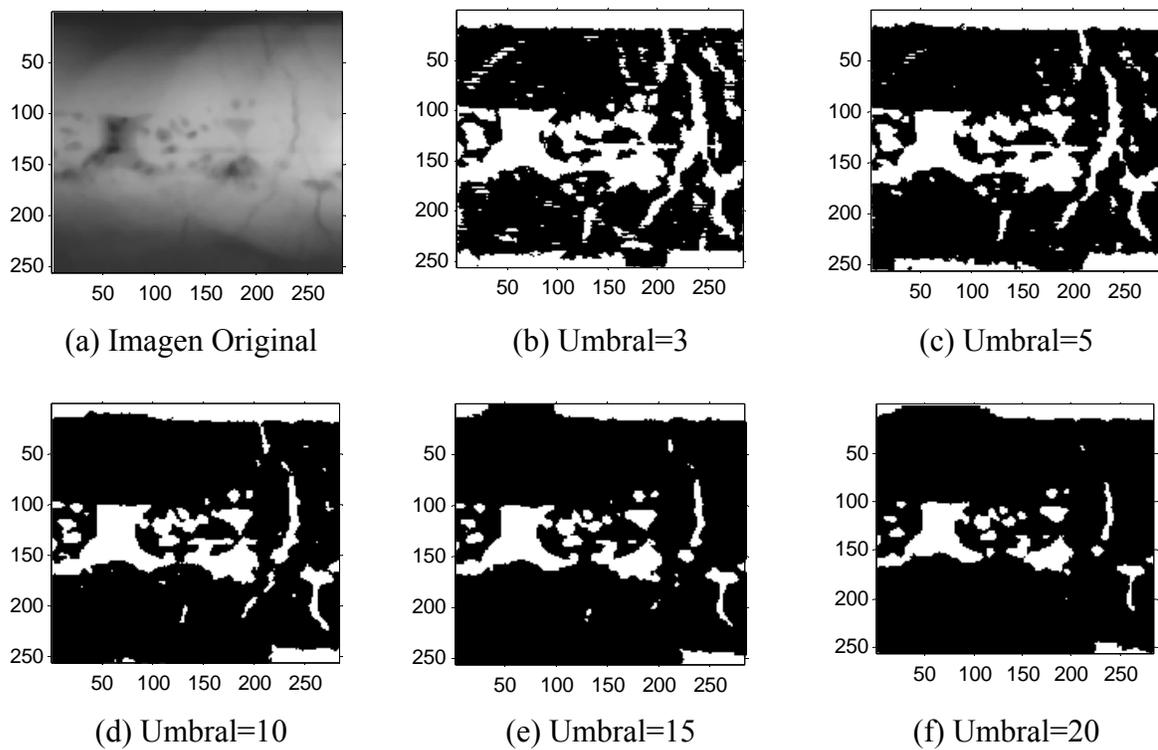


FIGURA 3.26 Esquema de umbralización fija a distintos valores de umbral

La figura 3.27 presenta un ejemplo de un histograma con una umbralización generalizada. En este caso, todos los niveles de gris que se encuentren en este rango son separados de los otros niveles fuera de ese rango.

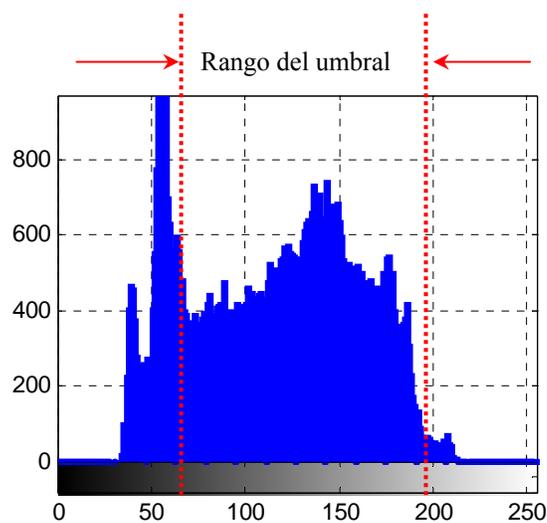


FIGURA 3.27 Histograma con rango de umbralización generalizada

La umbralización adaptativa tiene la ventaja de obtener los niveles específicos para cada región de la imagen. La idea consiste en dividir la imagen en regiones conexas que estén compuestas por niveles de gris con poca o nula variación; luego se determina el nivel de umbral para cada región. Si no se puede determinar el nivel de una subimagen, este se calcula a través de la interpolación con sus vecinos y finalmente se aplica la umbralización para cada región.

### 3.5.8 Transformada de Watershed

Un avance importante para la segmentación de regiones fue propuesta en 1979 por Beucher y Lantuéjoul (Beucher et al, 1979), los autores propusieron la transformada de Watershed como una herramienta para la segmentación de imágenes.

La metodología está basada en la morfología matemática, la cual consiste en dividir la imagen en conjuntos conexos. La idea de este método procede del campo de la topografía, en la cual una región topográfica es llenada de agua, formando distintas regiones que llenan los puntos mínimos de la función. Cuando el agua de dos regiones se une, se crean las líneas de división que son llamadas líneas de Watershed, este proceso se observa en la figura 3.28.

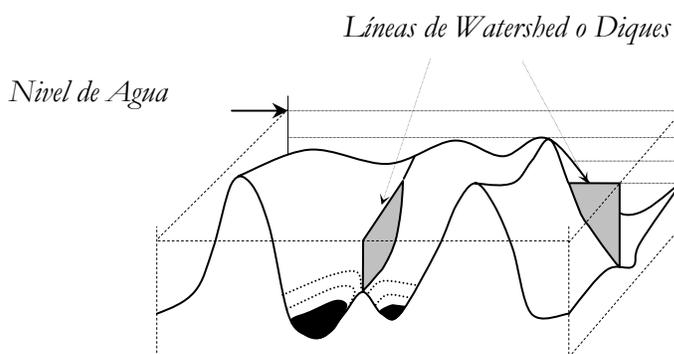


FIGURA 3.28 Construcción de las líneas de nivel (Soille et al, 1990)

El algoritmo original es muy lento y produce una sobreesegmentación de la imagen, especialmente cuando tiene ruido, por ello numerosos autores han propuesto distintas técnicas para mejorar su rendimiento y calidad de segmentación.

A principios de los 90, Soille y Vicent (Soille et al, 1990) proponen un algoritmo para segmentar las imágenes en forma más rápida. Su idea consistió en ordenar los píxeles de acuerdo a su valor de gris. A continuación se realiza un cálculo eficiente de las zonas de influencia geodésica a través de cada nivel del umbral; los sucesivos niveles de gris son procesados en orden para simular la propagación del llenado.

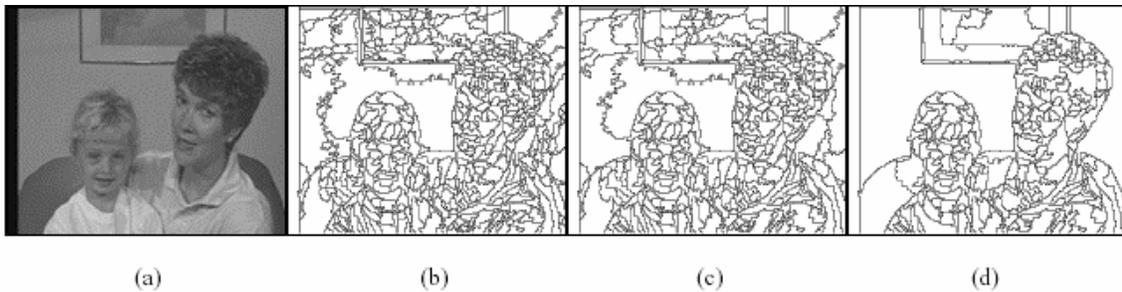
El proceso de análisis es implementado por un algoritmo basado en lista de espera. Un análisis detallado de la construcción de algoritmos para realizar la morfología de grises se encuentra en (Vincent, 1993).

Al año siguiente, Beucher (Beucher, 1991) propone una metodología distinta. Esta consistió en dividir la imagen en objetos con el fin de marcar los contornos más significativos en las áreas de interés. La modificación del gradiente se denominó “*Homotopy modification*”. El procedimiento se compone de dos etapas; primero, consiste en modificar la función del gradiente de manera que la nueva imagen reemplace los valores mínimos de la imagen original; estos nuevos puntos son llamados conjuntos de marcadores  $M$ . La segunda etapa consiste en aplicar Watershed al gradiente modificado. No obstante Beucher recomendó el uso de la función de la distancia como método para segmentar las imágenes antes de ser procesadas por Watershed.

Años más tarde, Meijster y Roerdink (Meijster et al, 1995) se basaron en el algoritmo propuesto por Vincent (Vincent et al, 1991) para desarrollar un algoritmo paralelo, debido principalmente a que los modelos propuestos aún tienen un alto costo en el consumo de tiempo, dado que el algoritmo de Watershed es inherentemente secuencial. La idea de fondo consistió en modelar el problema como un grafo dirigido, luego se realiza el método de Watershed en el grafo y para finalizar, se transforma el grafo etiquetado en una imagen binaria.

Los mismos autores realizan un nuevo estudio en 1998 (Meijster et al, 1998). La idea consistió en utilizar el algoritmo de Tarjan's en dos fases; la primera etapa consiste en transformar la imagen utilizando el algoritmo FIFO, en la segunda fase se procesa el algoritmo de Watershed sobre la imagen anterior, con el objeto que la implementación paralela sea más fácil de desarrollar.

Ese mismo año, Sang y Beom (Sang et al, 1998), proponen un algoritmo que representa objetos con pocas regiones, pero preservando su contorno (figura 3.29). El algoritmo está compuesto de cinco etapas; una simplificación de la morfología de la imagen, extracción de marcas, límite de decisión utilizando Watershed, unión de regiones pequeñas y finalmente, la unión de regiones homogéneas.



*FIGURA 3.29 Procesamiento de regiones vecinas (Sang et al, 1998)*

En el año 2001, Roerdink (Roerdink et al, 2001) presenta una recopilación de la transformada de Watershed. En ella se encuentra un completo análisis de los distintos algoritmos y su implementación, tales como; la definición de la función en el caso continuo, discreto, algoritmos por inmersión, a través de grafos, FIFO, detección de mínimos, algoritmos secuenciales y paralelos, definición por la distancia topográfica, condiciones locales, etc.

Uno de los últimos estudios fue realizado por Meyer y Vachier (Meyer et al, 2002). Ellos proponen la segmentación de imágenes a través de la simulación de fluido viscoso; la idea consiste en llenar las áreas de relieve por un conjunto de cilindros elementales; cada uno de estos cilindros llena los espacios abiertos; para hacerlo, los cilindros deben ser de distinto radio, a medida que se incrementa el radio se van llenando las regiones con fluido.

#### *3.5.8.1 Definición de la transformada de Watershed*

En esta sección se mostrará una descripción formal de la transformada de Watershed, una definición con mayor detalle se encuentra en (Vincent, 1991).

Sea  $G$  una imagen digital de escala de gris, donde  $G \in \mathbb{Z}^2 \times \mathbb{Z}^2$ . Existe una función  $f : D \rightarrow N$ , donde  $D$  es el dominio de la imagen (son las coordenadas de los píxeles) y algún  $p \in D$  donde el valor  $f(p)$  es el valor de gris del píxel. La imagen de escala de grises es mirada como un relieve topográfico en la cual  $f(p)$  muestra la altitud de la superficie en el punto  $p$ . Una ruta  $P$  de longitud  $l$  entre dos píxeles  $p$  y  $q$  es una  $l+1$ -tupla  $(p_0, p_1, \dots, p_{l-1}, p_l)$  tal que  $p_0 = p, p_l = q$  y  $\forall i \in [0, l) : (p_i, p_{i+1}) \in G$ .

Para un conjunto de píxeles  $M$  el predicado  $conn(M)$  es verdadero sí y sólo sí, por cada par de píxeles  $p, q \in M$  existe una ruta entre  $p$  y  $q$  en la cual sólo pasen los píxeles a través de  $M$ . El conjunto  $M$  es llamado conectado si se cumple con  $conn(M)$ . Una *componente conectada* es un conjunto de píxeles máximos conectados. Un *mínimo regional* de  $f$  y de altitud  $h$  es una componente conectada de píxeles  $p$  con  $f(p) = h$  en la cual es imposible alcanzar un punto de menor altitud sin tener que escalar. Sea cada mínimo de la superficie topográfica inmerso lentamente en un lago (figura 3.30).

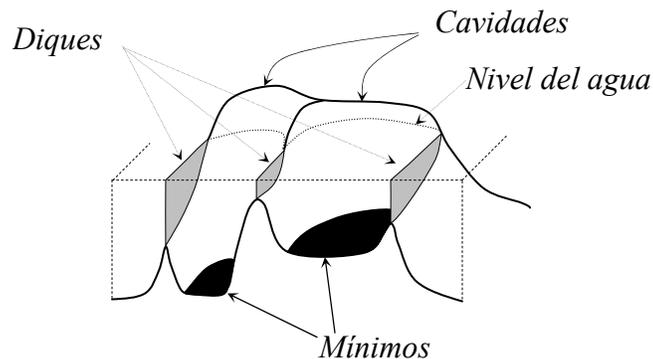


FIGURA 3.30 Cavidades y diques de Watershed (Soille et al, 1990)

El agua rellena los valles de la superficie creando cavidades. Cuando las regiones de dos cavidades o más se unen, se construye un dique. El conjunto de diques obtenidos al final del proceso de inmersión (cuando la superficie total es llenada), se denota como la transformada de Watershed de la imagen  $f$ .

Sea  $A$  un conjunto, y  $a, b$  dos puntos de  $A$ . La distancia geodésica  $d_A(a, b)$  en  $A$  es la ínfima longitud de todas las rutas de  $a$  para  $b$  en  $A$  (figura 3.31).

$$d_A(a, b) = \inf \{l(P), P\} \tag{3.21}$$

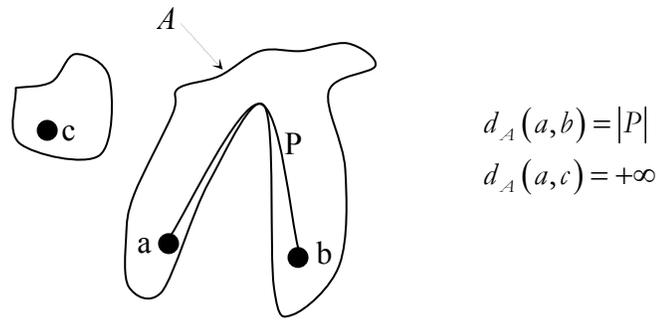


FIGURA 3.31 Distancia geodésica entre  $a$  y  $b$  (Meijster et al, 1995)

El caso digital utiliza para ello la función de la distancia. Sea  $A$  un conjunto de píxeles y sea  $B \subseteq A$  una partición de  $k$  componentes conectadas  $B_i$ , en donde:

$$B = \bigcup_{i=1}^k B_i \tag{3.22}$$

La zona de influencia geodésica del conjunto  $B_i$  dentro de  $A$  esta definida como

$$i_{\mathcal{Z}_A}(B_i) = \{p \in A \mid \forall j \in [1 \dots k] / \{i\} : d_A(p, B_i) < d_A(p, B_j)\} \text{ (figura 3.32).}$$

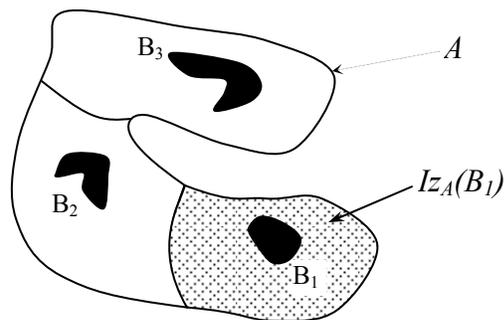


FIGURA 3.32 Zona de influencia geodésica (Meijster et al, 1995)

El conjunto  $IZ_A(B)$  está definido como la unión de las zonas de influencias de las componentes conectadas de B:

$$IZ_A(B) = \bigcup_{i=1}^k iZ_A(B_i) \quad (3.23)$$

Los puntos de A que no pertenecen a ninguna zona de influencia geodésica de  $IZ_A(B)$  dentro de A, son llamados el esqueleto de las zonas de influencia de A.

$$SKIZ_A(B) = A / IZ_A(B) \quad (3.24)$$

### 3.5.8.2 Algoritmo basado en grafos

El algoritmo basado en grafos propuesto por (Meijster et al, 1995) se describe básicamente a continuación. Suponga que la imagen no contenga mesetas, por lo tanto cada meseta representa a un píxel (figura 3.33).

$$\forall (p, q \in D : (p, q) \in G \Rightarrow f(p) \neq f(q)) \quad (3.25)$$

Esta observación permite realizar un algoritmo el cual consiste de tres pasos:

- Transformar la imagen  $f$  en un grafo dirigido  $f^* = (F, E)$  llamado componentes del grafo  $f$ .
- Calcular la transformada de Watershed del grafo dirigido.
- Transformar el grafo etiquetado en una imagen binaria, y calcular el esqueleto de las mesetas de Watershed.

#### Paso 1:

El primer paso consiste en transformar la imagen  $f$  en un grafo dirigido  $f^* = (F, E)$ , conocido como componentes del grafo de  $f$ .  $F$  es el conjunto de vértices del grafo y  $E$  es el conjunto de aristas. El conjunto de componentes en el nivel  $h$  está definido como:

$$L_h = \{C \subseteq T_h / T_{h-1} \mid C \text{ es una componente conectada de } T_h / T_{h-1}\} \quad (3.26)$$

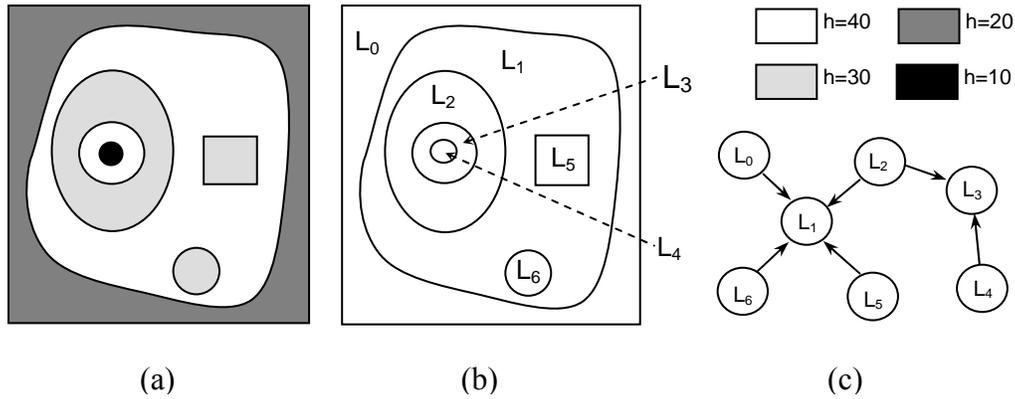


FIGURA 3.33 (a) Imagen original, (b) Separación de la imagen en sus niveles de gris, (c) Generación del grafo etiquetado de Watershed (Meijster et al, 1995)

El conjunto de vértices del grafo  $f^*$  es una colección de componentes de nivel de  $f$ .

$$F = \bigcup_{h=h_{\min}}^{h_{\max}} L_h \tag{3.27}$$

Un par del conjunto  $(v, w)$  es un elemento de  $E$ , sí y sólo sí:

$$\exists (p \in v, q \in w : (p, q) \in G \wedge f(p) < f(q)). \tag{3.28}$$

**Paso 2:**

En este paso se calcula el algoritmo de Watershed a través del grafo dirigido. La idea básica es asignar un color a cada mínimo y asociar las cavidades llenando iterativamente el grafo usando un algoritmo de búsqueda. Si un nodo  $v$  puede ser asignado a dos o más diferentes vértices, o sea si el nodo puede ser leído por dos o más cavidades a lo largo de la ruta, entonces el nodo es marcado como un nodo de Watershed. Si el nodo puede ser sólo leído por nodos en los cuales se tiene la misma etiqueta, el nodo es asignado a la misma etiqueta, por lo tanto, el nodo es unido con su correspondiente cavidad.

**Paso 3:**

El tercer y último paso consiste en transformar el grafo etiquetado en una imagen, los píxeles que han sido catalogados como nodos de Watershed son coloreados en blanco, en cambio los otros píxeles son coloreados en negro. Después de este paso la imagen queda binarizada, por lo cual es necesario realizar un proceso para determinar el esqueleto de la imagen (figura 3.34). Existen distintos tipos de algoritmos de esqueletización, sin embargo, estos pueden dar diferentes resultados.

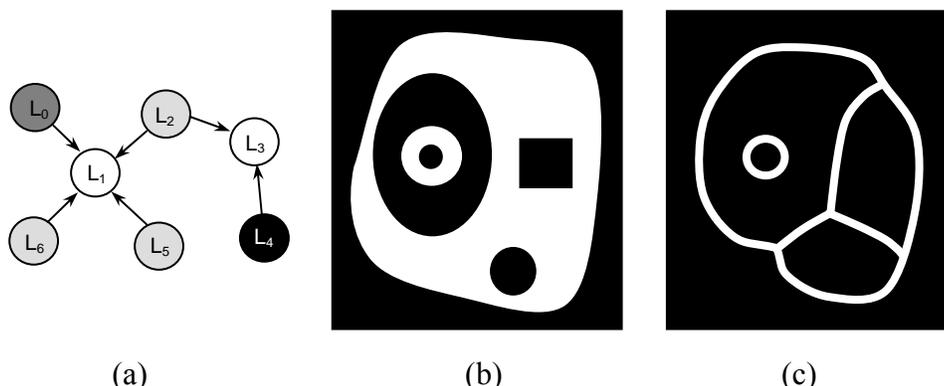


FIGURA 3.34 (a) Grafo etiquetado, (b) Generación de la imagen binaria a partir de los niveles de gris, (c) Esqueletización del grafo de Watershed (Meijster et al, 1995)

**3.5.9 Transformada de la distancia:**

La transformada de la distancia es un operador normalmente sólo aplicado a imágenes binarias (Breau et al, 1995). El resultado de la transformación es una imagen en niveles de gris que es similar a la imagen de entrada, excepto que la intensidad de los niveles de gris de cada punto dentro de la región, es modificada para mostrar la distancia de los bordes cerrados desde cada punto.

Hay varias clases distintas de la transformada de la distancia, dependiendo en que métricas de distancia será utilizada para determinar la distancia entre píxeles. Una vez que la métrica ha sido escogida, existen distintas maneras de calcular la transformada de la distancia para una imagen binaria.

La primera idea consiste en realizar múltiples erosiones sucesivas de estructuras elementales hasta que todas las regiones de la imagen han sido erosionadas. Si cada píxel, se etiqueta con un número de acuerdo a las erosiones aplicadas (hasta que no queden más regiones), se genera una imagen que representa la cantidad de veces que han sido erosionados los píxeles.

Las métricas de la distancia son muy utilizadas en el procesamiento de imágenes para calcular la distancia entre dos píxeles. La presencia de una matriz de píxeles llamada distancia métrica, hace posible calcular la distancia entre un par de puntos. Se muestran a continuación las más utilizadas.

### 3.5.9.1 Distancia Euclidiana:

Si dos píxeles son considerados como coordenadas  $(x_1, y_1)$  y  $(x_2, y_2)$  entonces la distancia Euclidiana está dada por:

$$D_{EUCLIDIANA} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (3.29)$$

### 3.5.9.2 Distancia “City Block”

Esta métrica asume que ir de un píxel a otro es sólo posible viajando directamente a lo largo de las líneas de las grillas de los píxeles. Las movidas diagonales no son permitidas. Por lo tanto la distancia “City Block” está dada por:

$$D_{CITY\ BLOCK} = |x_2 - x_1| + |y_2 - y_1| \quad (3.30)$$

### 3.5.9.3 Distancia “Chessboard”

Esta métrica asume que se puede mover en una grilla de píxeles, si es el rey en una movida de ajedrez. Las movidas diagonales cuentan de la misma forma que una movida horizontal. Esto significa que la métrica está dada por:

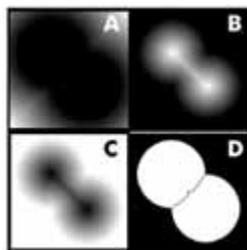
$$D_{CHESSBOARD} = \max(|x_2 - x_1|, |y_2 - y_1|) \quad (3.31)$$

El objetivo de utilizar la transformada de la distancia, consiste en disminuir la sobresegmentación de la imagen. Para demostrar su uso, se presenta un ejemplo de una imagen que se desea separar. Suponga que se tiene una imagen binaria con dos círculos insertos con bordes abiertos (figura 3.35). El objetivo en este caso es separar los dos círculos en regiones disjuntas.



*FIGURA 3.35 Ejemplo de círculos no cerrados (Eddins, 2002)*

Al aplicar la transformada de la distancia sobre la figura 3.35, queda como resultado la figura 3.36a, sin embargo, esta imagen aún debe ser procesada para utilizar Watershed ya que aún no forman cavidades separables.



*FIGURA 3.36 Aplicación de la transformada de la distancia y la transformada de Watershed (Eddins, 2002).*

Para ello se calcula la transformada de la distancia del inverso de la imagen 3.35; esto se muestra en la figura 3.36b. En este caso se ven dos cavidades, no obstante, esta imagen aún no puede emplearse, ya que las regiones más brillantes, representan los puntos altos. Para solucionar esto, se debe calcular la inversa de la imagen en la figura 3.36b, de este modo queda la figura 3.36c. Con esta última imagen se puede aplicar Watershed, ya que basta con llenar las regiones más bajas para que se conecten las líneas de aguas o diques, quedando como resultado la figura 3.36d,

la cual es idéntica a la figura 3.35, sólo que en esta última, se ha completado la línea divisoria de Watershed.

En la figura 3.37b, se muestra la representación de la línea de Watershed una vez aplicada la transformada a la imagen inicial. En este caso, se aprecia que los valores más oscuros generados por la transformada de la distancia, son los puntos más bajos de las cavidades generadas en la figura tridimensional. Se observa además, que se ha generado una línea divisoria la cual separa las dos cavidades.

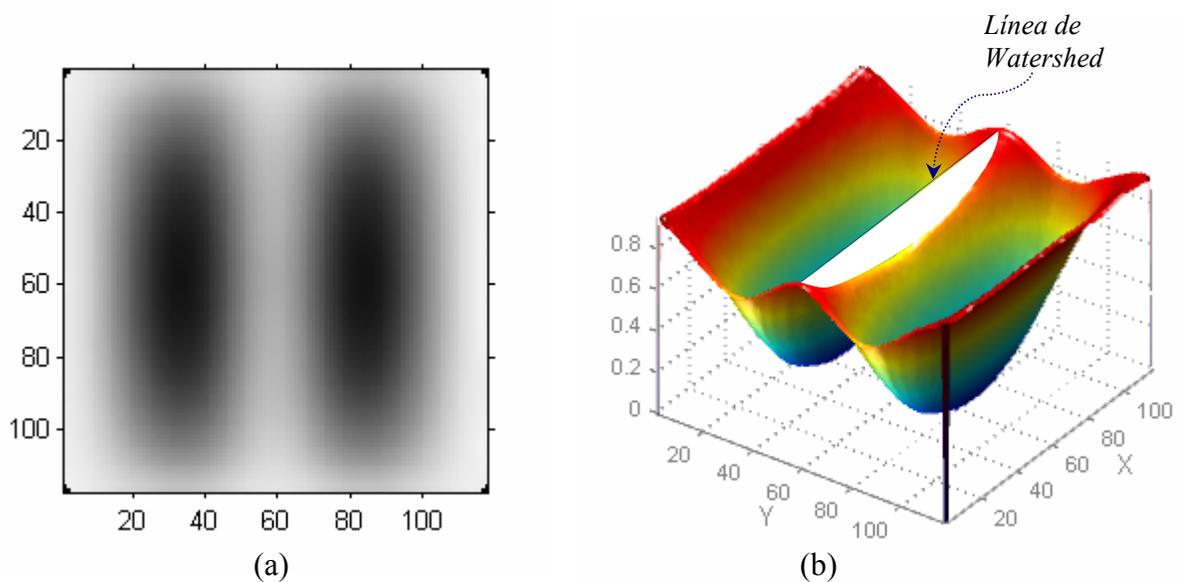
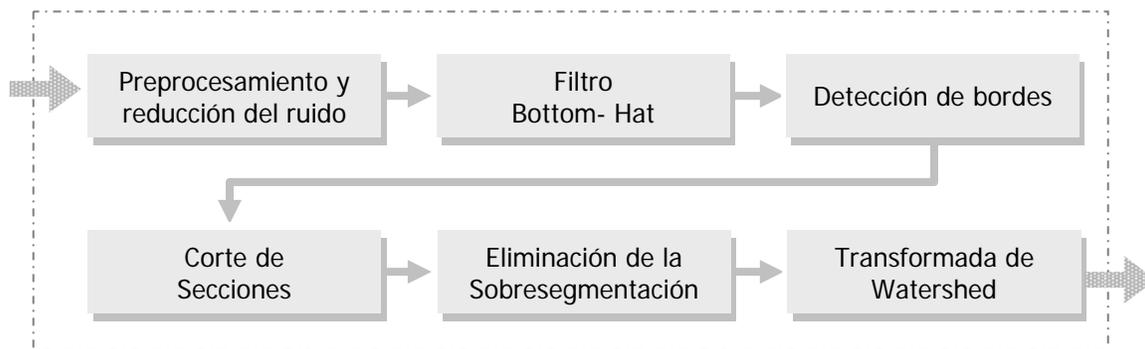


FIGURA 3.37 (a) Imagen original en 2D, (b) Representación tridimensional de la aplicación de la transformada de Watershed sobre (a)

## CAPÍTULO 4 DESARROLLO DE LA SOLUCIÓN

En este capítulo, se aplican las distintas estrategias y metodologías mostradas en la sección anterior, para el desarrollo de un método de segmentación que permita mejorar la calidad en la detección de fallas en soldaduras. En la construcción de la solución, se han utilizado distintas técnicas de procesamiento digital, por lo cual, es necesario determinar cuales técnicas en conjunto permiten mejorar el resultado global de la segmentación.

La solución está compuesta por un conjunto de etapas, donde cada una de ellas es analizada en forma independiente, permitiendo cuantificar y analizar las ventajas y desventajas de su utilización. En algunos casos se ha estudiado diferentes estrategias para una misma etapa, por lo cual, se debe realizar una elección del método que mejore el resultado global. En la figura 4.1, se presenta un esquema general del proceso de segmentación propuesto, sin considerar específicamente los filtros a utilizar en cada etapa, debido a que este capítulo determina las mejores técnicas para cada fase.



*FIGURA 4.1 Proceso de segmentación general*

Además de analizar las diferentes estrategias para cada una de las etapas, se desarrollaron dos líneas de segmentación utilizando las técnicas estudiadas en los fundamentos teóricos. La primera está compuesta por el uso del método de Canny y la segunda línea utiliza el método de umbralización. Las diferencias radican en el método de detección de bordes a utilizar ya que, en

el caso de Canny es necesario realizar operaciones derivativas para obtener las regiones con fallas; en el caso del método de umbralización, es necesario realizar un procedimiento que elimine el ruido anexado a la imagen binaria producto del nivel del umbral seleccionado.

#### 4.1 PREPROCESAMIENTO Y REDUCCIÓN DEL RUIDO

Según el estudio presentado en la sección 3.3, se ha podido determinar experimentalmente que el filtro de la mediana ha tenido un mejor rendimiento en comparación con el filtro Gaussiano y el filtro promedio, debido principalmente a la eliminación de gran parte del ruido, además de preservar los bordes de las fallas (figura 4.2)

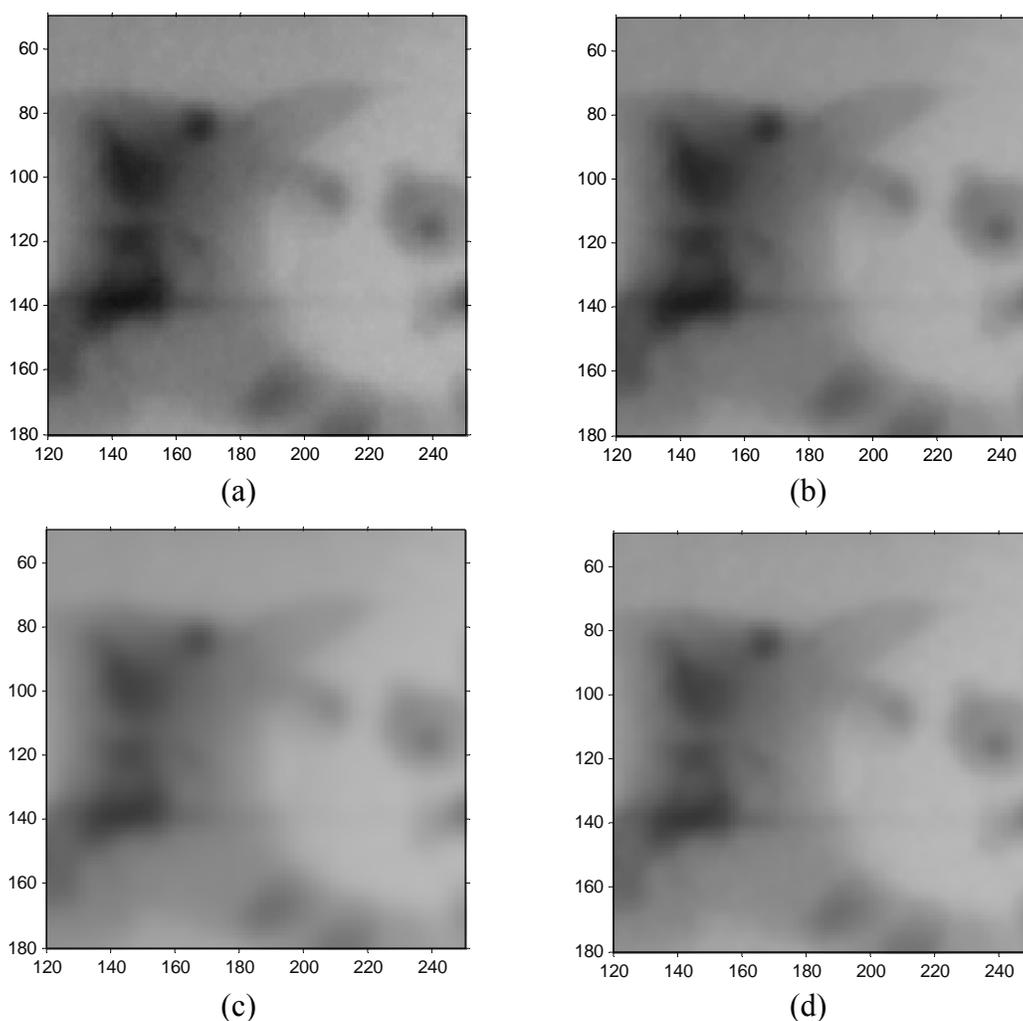


FIGURA 4.2 (a) Imagen original, (b) Aplicación del filtro de la mediana de 3x3, (c) Aplicación del filtro Gaussiano de 9x9 con  $\sigma = 1$ , (d) Aplicación del filtro promedio de 5x5

En la figura 4.2b se ha aplicado el filtro de la mediana, observándose que se han preservado los bordes de las estructuras; además en las zonas circundantes a las fallas se han mantenido los píxeles de la imagen original. El filtro Gaussiano ha sido utilizado en la figura 4.2c; se aprecia que el difuminado de las estructuras con fallas se ha combinado con las regiones circundantes, lo cual es perjudicial para la posterior fase de segmentación, debido al problema para determinar los posibles bordes de las fallas hipotéticas.

Finalmente en la figura 4.2d, la aplicación del filtro promedio no ha superado la calidad con respecto al filtro de la mediana, sin embargo, sus resultados han sido mejores en comparación con el filtro Gaussiano debido a que la pérdida en la definición de los bordes ha sido en menor grado, debido al tamaño de la máscara aplicada a la imagen. No obstante, la intensidad en los niveles de gris es inferior con respecto a la mediana, por lo cual, las estructuras igualmente han perdido definición. Tal como en el caso Gaussiano, el filtro promedio no ha demostrado una mejora en la eliminación del ruido sin pérdida de la definición.

## 4.2 FILTRO BOTTOM-HAT

El filtro bottom-hat es utilizado para destacar las estructuras con fallas hipotéticas y separarlas de su fondo (Mathworks, 2003). Este proceso consta de dos fases: primero se emplea el operador morfológico de la cerradura en la imagen original, por lo cual se requiere que el tamaño de núcleo aplicado a la cerradura permita eliminar la mayoría de las fallas hipotéticas, en consecuencia, se genera un fondo similar al de la imagen original pero sin fallas. En la segunda fase se utiliza el operador de substracción entre la imagen original y la imagen modificada de la primera fase.

El resultado obtenido permite revelar varias estructuras de menor tamaño, las cuales están compuestas en gran medida por fallas, y debido a la separación de estas con su fondo, se puede aplicar distintos métodos para segmentarlos y analizarlos. En este punto se ha analizado dos variantes: la primera consiste en encontrar los bordes utilizando el método de Canny y la segunda en aplicar un método de umbralización binaria.

La figura 4.3b muestra la aplicación del operador de la cerradura; se aprecia que la diferencia entre el fondo de la imagen original y el fondo generado a partir de la cerradura es mínima. Mientras más se aproxime al fondo original, mayor es la cantidad de estructuras captadas; este valor es regulado de acuerdo al tamaño del núcleo con el cual se ha generado la cerradura. En la figura 4.3c se encuentran estructuras que tienen fallas y en menor medida hay ruido, producto de la operación de sustracción entre la figura 4.3a y la figura 4.3b. Con el propósito de mejorar la visualización del resultado, se presenta la figura 4.3d con un cambio en el mapa del color a un formato HSV (Hue Saturation Value).

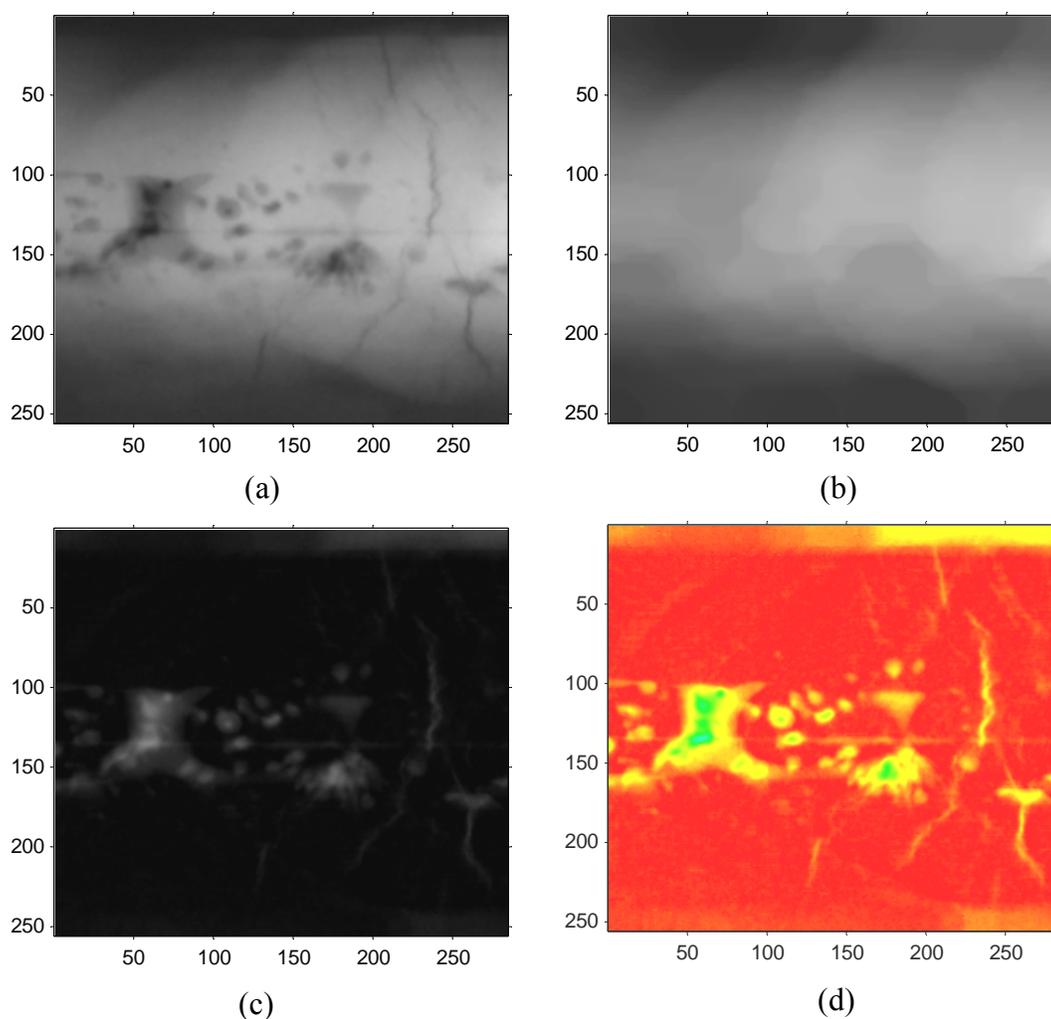


FIGURA 4.3 (a) Imagen original, (b) Aplicación del operador de la cerradura sobre la imagen original, (c) Diferencia entre la imagen (a) y (b), (d) Figura 4.3c en pseudocolor.

### 4.2.1 Eliminación de las señales débiles

El resultado del filtro bottom-hat genera captaciones de bajo nivel que son eliminadas con un ajuste en el nivel del umbral, ya que es considerado como ruido. Para eliminar estas regiones de baja intensidad, se modifica la escala de grises de la figura 4.3c, quedando como resultado la figura 4.4a; para ello se utiliza el operador de MATLAB *'imadjust'*. Esta función modifica los niveles de intensidad de la imagen original, variando los valores entre el mínimo y máximo de la entrada a un nuevo mínimo y máximo en la salida, que por defecto se encuentran entre 0 y 1; los valores que se encuentran fuera de ese rango son eliminados. Otro parámetro de la función, es la corrección Gamma, que permite modificar la escala de salida a través de una función no lineal; cuando el parámetro es unitario la corrección es lineal, en cambio un valor superior a 1, genera una curva que aumenta el nivel de brillo de la imagen, y un valor inferior a 1 genera una curva que disminuye la intensidad de la imagen.

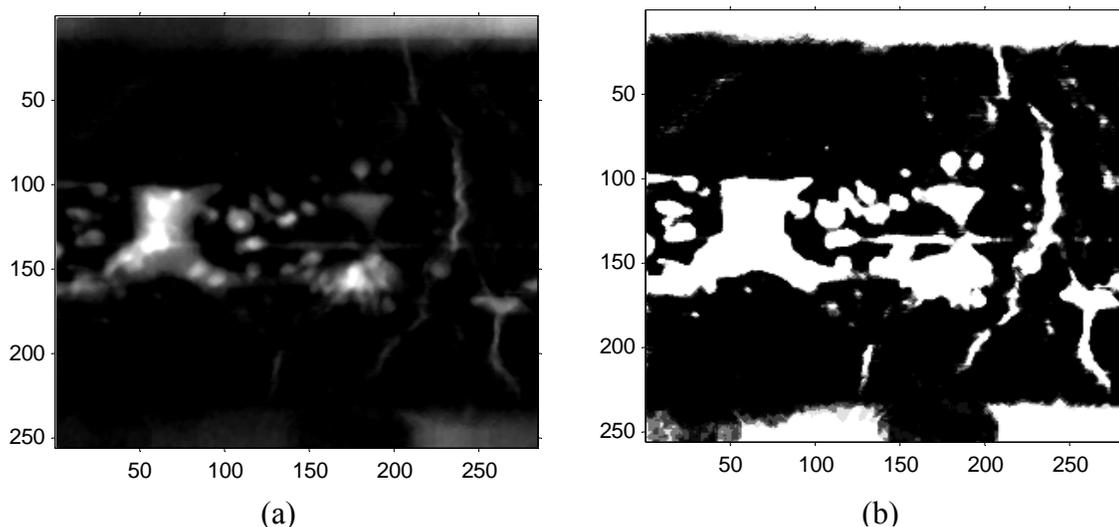


FIGURA 4.4 (a) Imagen con corte desde 0.015 a 0.30, (b) Operación de la multiplicación de la figura 4.4a

En la figura 4.4a, se ha modificado los valores de entrada tomando los niveles de gris entre 0.015 y 1 de un rango entre 0 y 1. Esto significa que los niveles de intensidad entre 0 y 0.015 son eliminados, y en la imagen de salida los valores entre 0.015 y 1 son nivelados a 0 y 1, manteniendo el valor lineal de gamma. Luego se utiliza el operador de la multiplicación, ya que

permite modificar los niveles de intensidad de la imagen, mejorando los niveles de brillo y preservando los bordes. En este caso la multiplicación se ha efectuado con la imagen 4.4a, de este modo, se remarcan las regiones con mayor nivel de gris. El resultado de la operación se aprecia en la figura 4.4b.

## 4.3 DETECCIÓN DE BORDES

### 4.3.1 Estrategia de Canny

En esta estrategia se define la solución utilizando el método de Canny y las operaciones de dilatación, llenado y erosión. El proceso se inicia al aplicar el método de Canny sobre la figura 4.4b, la cual genera la figura 4.5a.

Se observa que se han formado líneas alrededor de las estructuras captadas, sin embargo, es necesario cerrarlas ya que el objetivo consiste en generar un conjunto de regiones cerradas a partir de estas líneas y, de esta manera, segmentar las fallas hipotéticas del fondo de la imagen. El proceso continúa con la aplicación de la dilatación mostrada en la figura 4.5b. La utilización de este operador permite cerrar la mayoría de las regiones abiertas. Luego se rellenan las regiones cerradas de la operación anterior; este proceso se ilustra en la figura 4.5c. Finalmente se aplica el operador de la erosión para invertir el efecto de la dilatación y además determinar con mayor precisión las zonas con fallas de regiones ya cerradas.

El método de Canny detecta con mayor precisión los bordes de las estructuras debido a que es menos sensible al ruido, dado que utiliza un filtro Gaussiano para disminuirlo, sin embargo, genera una gran cantidad de bordes abiertos, razón por la cual es necesario realizar el proceso de dilatación, llenado y erosión. La desventaja se encuentra precisamente en la generación de bordes abiertos, como se aprecia en la figura 4.5d; la flecha amarilla indica una línea que no se ha cerrado, y que el método de Canny ha detectado, pero esta línea no forma una estructura que pueda cerrarse, aún cuando durante el proceso de dilatación y llenado se ha incrementado su grosor; la operación de erosión la transforma a su estado original. En otra zona, la flecha roja

indica la formación de una curva, lo cual sugiere la presencia de una estructura con falla, sin embargo, nuevamente el proceso de dilatación no genera una región cerrada.

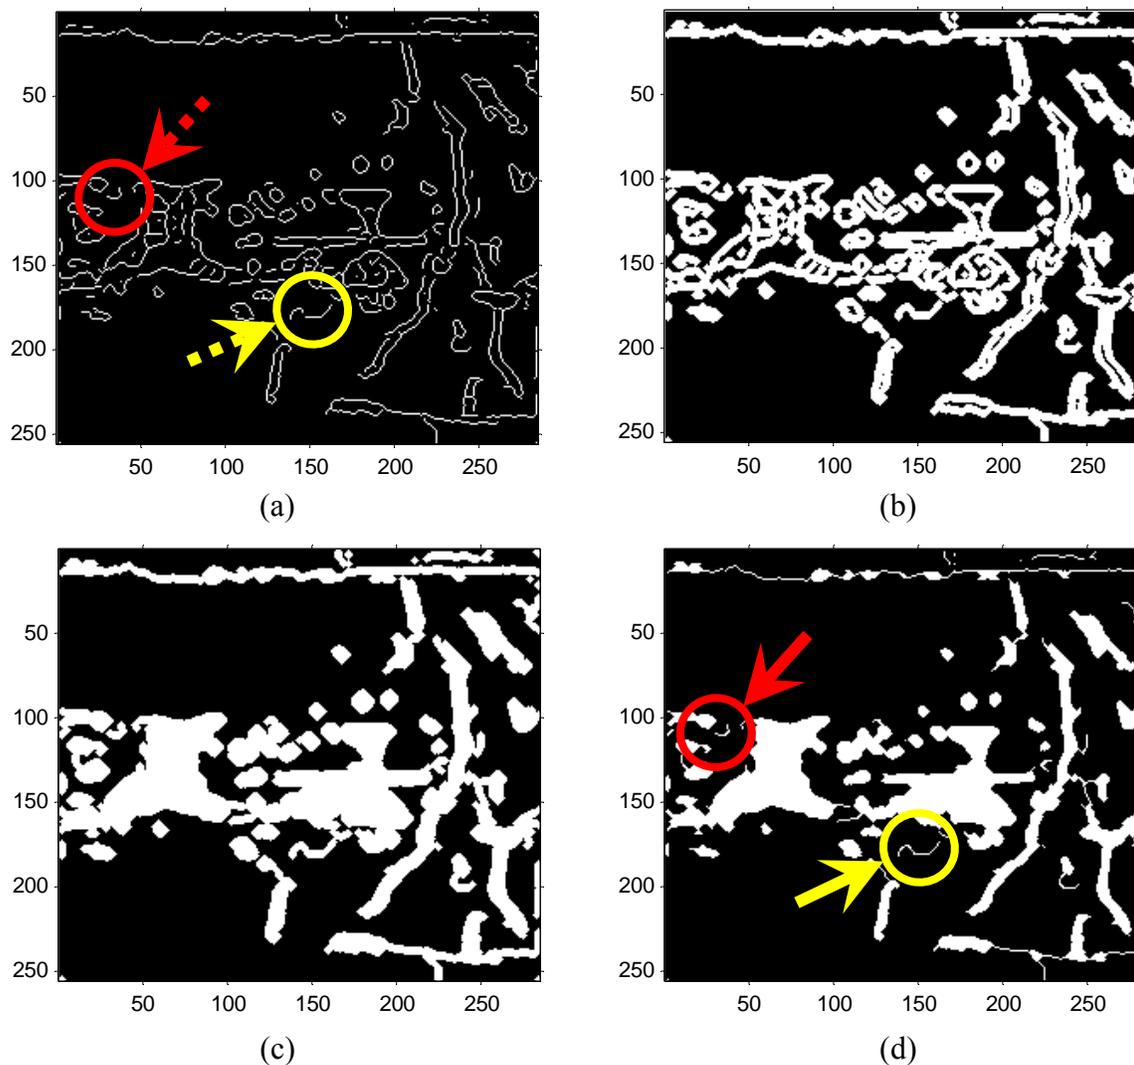


FIGURA 4.5 (a) Generación de bordes con el método de Canny, (b) Dilatación de los bordes de (a), (c) Relleno de las regiones cerradas de (b), (d) Erosión de las estructuras de (c)

Como se presenta en la figura 4.6a, se ha estudiado incrementar el valor de la dilatación durante el proceso y que la estructura utilizada en la erosión sea menor a la dilatación, con la idea de evitar formar líneas. Pero los resultados experimentales muestran que este cambio afecta la formación de regiones, ya que el aumento en la dilatación permite que regiones distantes que no

estén unidas, se unan formando puentes, tal como se aprecia en las flechas de la figura 4.6a. Al aplicar el operador de llenado, se llenan regiones que no deben ser llenadas. La región indicada con flechas de la figura 4.6b, muestra la formación de una estructura que une tanto zonas con fallas como zonas normales, dando como resultado una segmentación de regiones imprecisa.

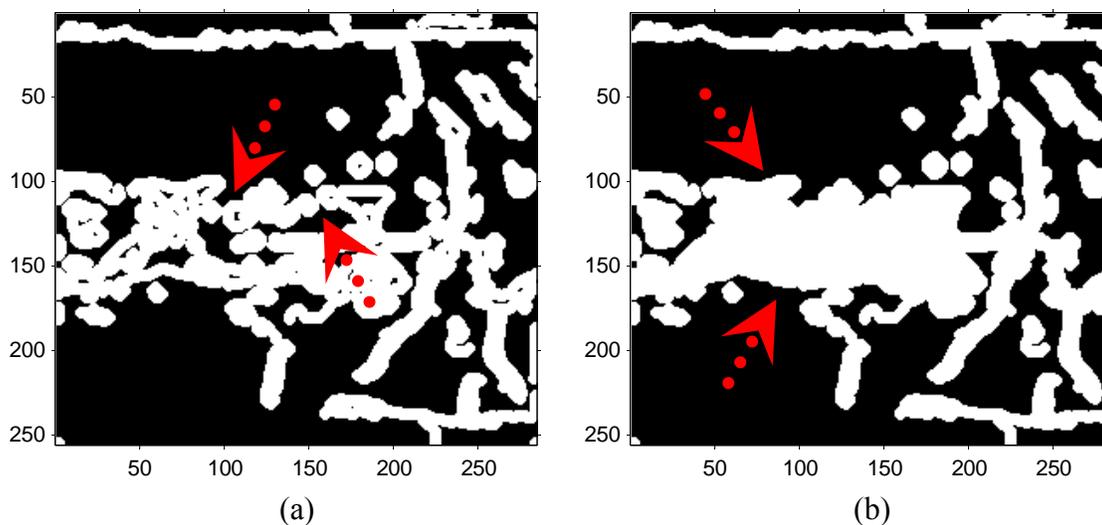


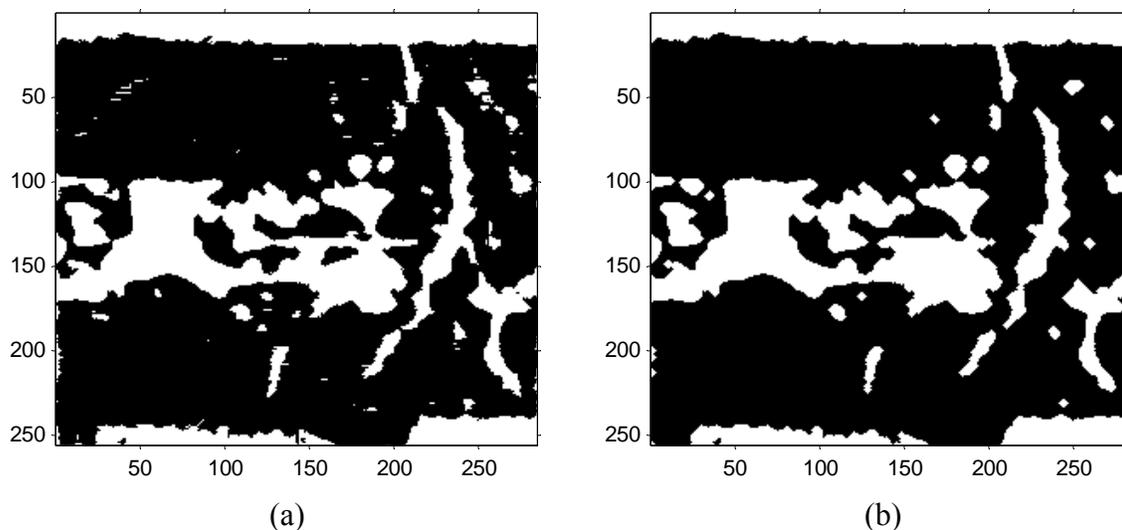
FIGURA 4.6 (a) Dilatación de los bordes en mayor grado, (b) Relleno de las regiones cerradas de la figura 4.6a

### 4.3.2 Estrategia umbralización binaria

La estrategia de umbralización binaria consiste en aplicar este operador sobre el resultado generado por el filtro bottom-hat (figura 4.4b). De este modo, se obtienen regiones cerradas que pueden ser definidas por un umbral determinado. Si se desea aumentar la captación de regiones, se disminuye el valor del umbral para que este deje pasar una mayor cantidad de niveles de gris, en cambio si se aumenta el umbral, se capta una menor cantidad de regiones.

No obstante, la utilización de este operador genera ruido que es incorporado a la figura 4.7a. La solución consiste en aplicar el operador apertura, lo cual genera como resultado una imagen con

un bajo nivel de ruido y con estructuras uniformes y cerradas. El operador apertura puede ser regulado, cambiando el tamaño de las estructuras con la cual se aplica la erosión y la dilatación.



*FIGURA 4.7 (a) Imagen binaria producto de la umbralización, (b) Aplicación de la apertura sobre la imagen (a)*

La principal desventaja frente a la estrategia anterior se debe a la menor detección de bordes; ahora bien, los resultados indican que el método de Canny genera una gran cantidad de bordes en forma de líneas sin la posibilidad de cerrarlos. En cambio, la ventaja de la umbralización binaria consiste en generar la mayoría de las regiones con fallas ya cerradas, ya que sólo requiere de un proceso de eliminación del ruido que se puede aplicar eficientemente con los operadores morfológicos.

#### **4.4 CORTE DE SECCIONES**

El corte de secciones requiere de la aplicación de la umbralización binaria. La idea consiste en destacar y segmentar sólo las regiones con fallas hipotéticas. En este punto se definen dos estrategias, la primera consiste en rescatar los píxeles de la imagen original a partir del resultado de la umbralización binaria; se utiliza el resultado anterior como una plantilla que se sobrepone en la imagen original (figura 4.8a), de esta manera, se define que todas las zonas o píxeles que

sean negros se transformen en blancos, y los píxeles blancos de la imagen binaria, se utilicen para copiar todos los píxeles de la imagen original en la misma posición.

La segunda estrategia utiliza la transformada de la distancia sobre las regiones blancas, para generar una superficie en escala de grises según la distancia de su centro respecto a sus bordes, y los píxeles negros se transforman en blancos ya que son regiones que no tienen fallas. El objetivo consiste en tener un mapa de las estructuras con fallas, ya sea generado a través de la transformada de la distancia o como una copia de la imagen original, ya que el siguiente proceso utiliza los niveles de gris para la construcción de líneas de segmentación a través de la transformada de Watershed.

#### 4.4.1 Estrategia de corte de la imagen original

Esta estrategia copia sólo las áreas que son factibles de tener fallas de la imagen original; para hacerlo utiliza la figura 4.8a como una plantilla que se sobrepone sobre la imagen original generando una imagen donde sólo se presentan las estructuras con fallas; el resultado de esta operación se muestra en la figura 4.8b.

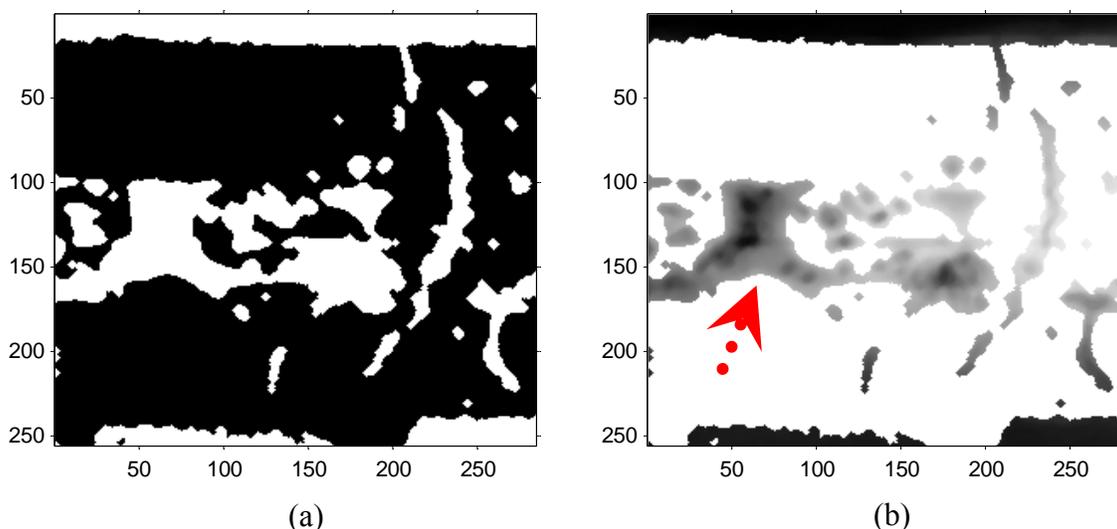


FIGURA 4.8 (a) Imagen binaria, (b) Corte de regiones a partir de la umbralización binaria

Se observa que las áreas negativas de la plantilla son transformadas a positivas; la razón de este cambio está sujeto al posterior proceso a través de la transformada de Watershed, en la cual, las áreas positivas representan los puntos superiores de una formación geológica, y los puntos negativos son los puntos más bajos; esta representación se muestra en la figura 4.9.

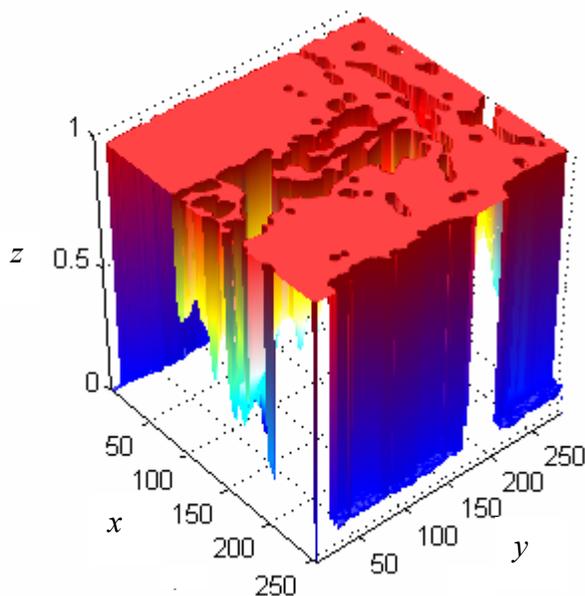


FIGURA 4.9 Representación tridimensional del corte de la imagen original en pseudocolor

#### 4.4.2 Estrategia de corte con la transformada de la distancia:

Al aplicar la transformada de la distancia a una imagen binaria que tenga una forma antropomórfica, se obtienen resultados indeseados para el posterior análisis con Watershed ya que la escala de grises resultante, puede no representar necesariamente la superficie que se desea dividir. La figura 4.10a muestra una sección de la figura 4.8b; se observa claramente las diferencias de los niveles de gris entre la sección de corte de la imagen original, con respecto a la sección generada, utilizando el operador de la transformada de la distancia.

En caso de tener figuras circulares cerradas, las diferencias pueden ser menores ya que la formación resultante del operador de la distancia tiene la misma característica que la imagen original. Sin embargo, las imágenes que se encuentran en estudio, generalmente tienen forma y escalas de grises muy variadas, y no representan formas exactas como las mencionadas anteriormente. En este sentido, la aplicación de la transformada de la distancia, puede no ser recomendable para el tipo de fallas que se está analizando, ya que no representa la forma de los niveles de gris de la imagen original.

La figura 4.10a es el resultado obtenido al aplicar el umbral a una imagen con fallas, luego la imagen binaria es sobrepuesta sobre la original, quedando como resultado, sólo las zonas de interés para el análisis con Watershed. La figura 4.10b es el resultado de aplicar la transformada de la distancia a una imagen binaria con la misma forma y estructura que la figura 4.10a, para luego invertir su escala de grises. Como se puede apreciar, a partir de dos estructuras iguales, se obtienen imágenes muy distintas, por lo cual, la aplicación de Watershed sobre estas imágenes, genera resultados diferentes.

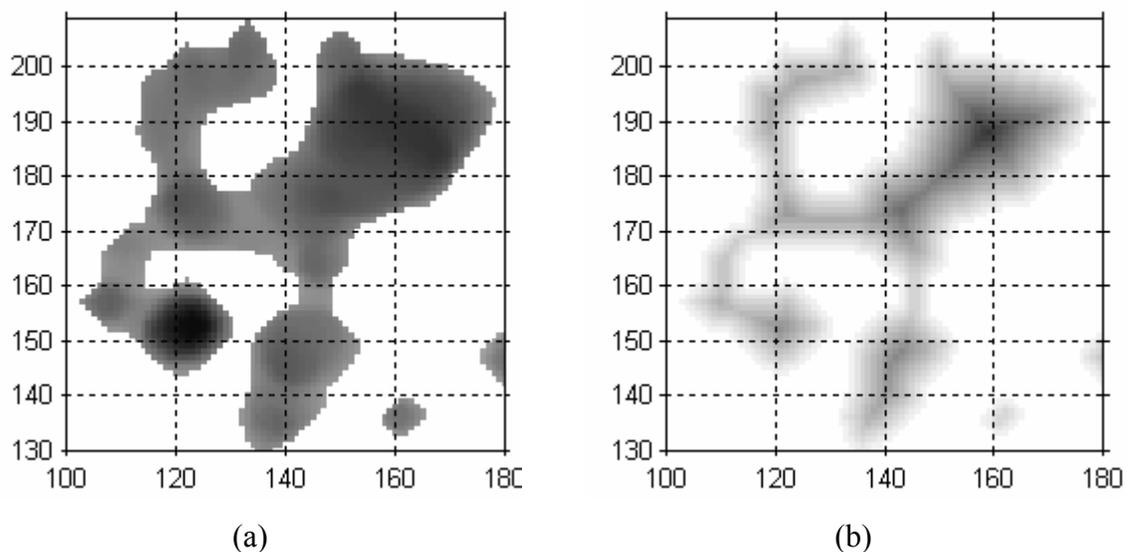


FIGURA 4.10 (a) Selección de falla a través del corte de la imagen original, (b) Generación de estructura utilizando la transformada de la distancia

El resultado del procesamiento se presenta en la figura 4.11. En el primer caso, se tiene la aplicación de Watershed sobre la figura 4.10a; en el segundo, la aplicación sobre la figura 4.10b. El resultado experimental muestra que en el primer caso la división fue más precisa, ya que se obtienen divisiones de acuerdo a la imagen real y no a una imagen simulada como es la generada por la transformada de la distancia.

Otra característica del resultado de la figura 4.11b, es que los cortes de la segmentación son en mayor grado más rectos que los de la imagen real, siendo esto, otro punto negativo con respecto a la utilización de este operador. Además existen divisiones en la figura 4.11a que no existen en la figura 4.11b

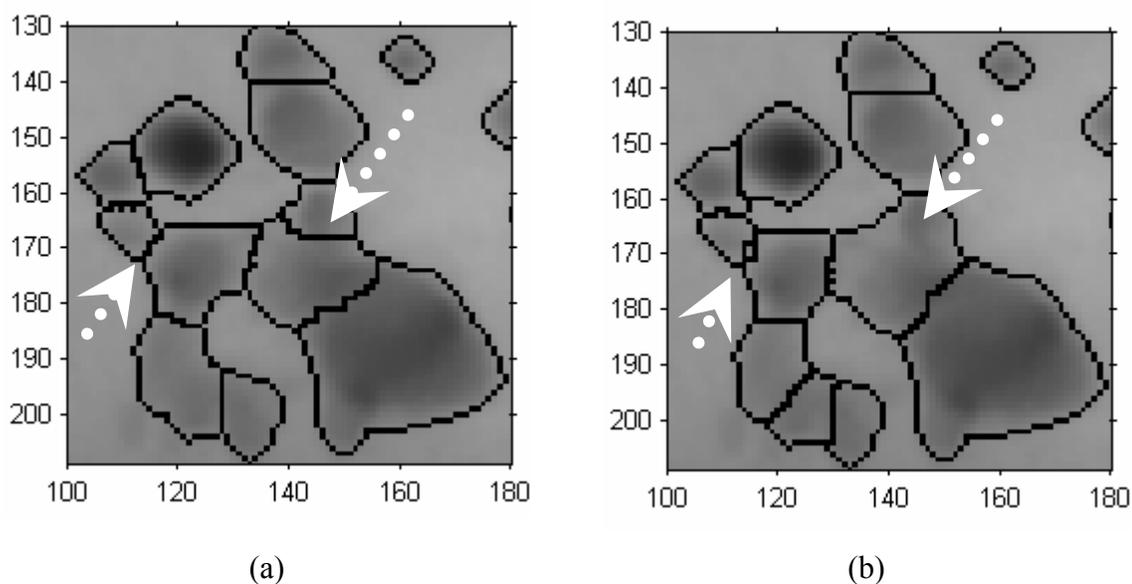


FIGURA 4.11 (a) Aplicación de bordes de Watershed con la tonalidad original, (b) Aplicación de bordes de Watershed con la transformada de la distancia

## 4.5 ELIMINACIÓN DE LA SOBRESSEGMENTACIÓN

Las imágenes en escala de grises pueden ser transformadas al espacio tridimensional. Para ello cada píxel de la imagen bidimensional es transformado a una forma tridimensional utilizando como posición su coordenada  $(x,y)$  y como elevación su nivel de gris. En esta interpretación, los

valores de la intensidad representan las elevaciones tal como un mapa topográfico. Las áreas de alta y baja intensidad en una imagen son las cimas y valles, respectivamente. Las características morfológicas representadas son importantes ya que ofrecen marcas relevantes para una imagen.

La región central de la figura 4.12a presenta fallas de soldaduras de formas circulares y longitudinales; en el caso de la figura 4.12b, estas estructuras forman cavidades o valles. Es simple notar la presencia de una falla en el caso de la representación tridimensional, ya que se muestra como una cavidad, producto de un cambio en la intensidad de los niveles de gris. En las zonas donde no hay fallas se presenta una rugosidad suave, propia del material. Usando el procesamiento morfológico, esta máxima puede ser usada para identificar objetos en una imagen.

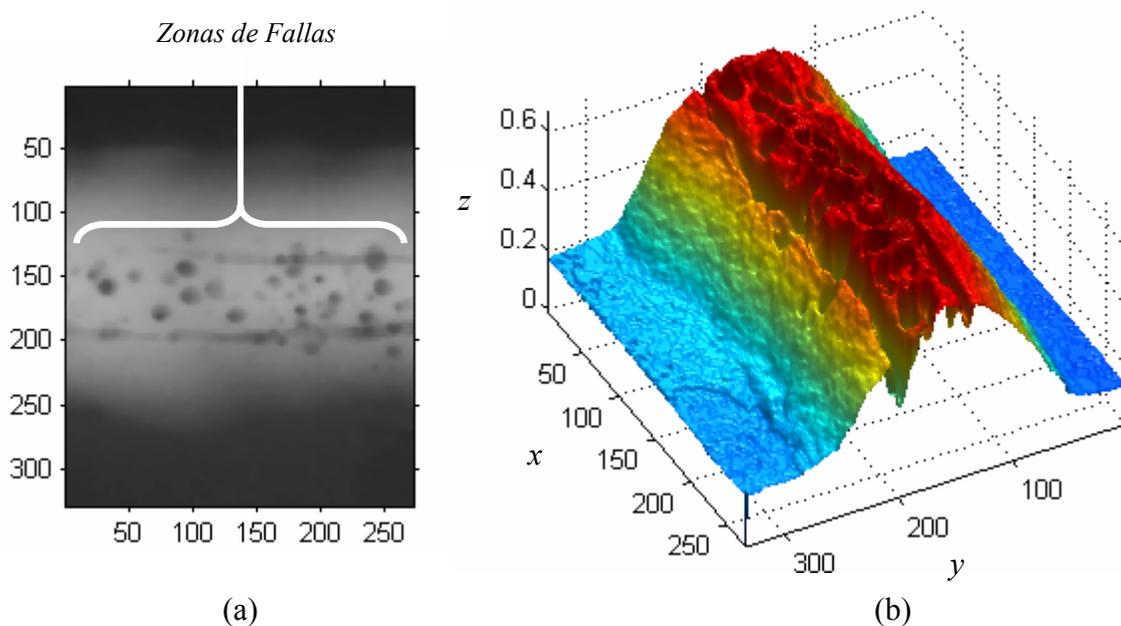


FIGURA 4.12 (a) Sección de BAM-5 en su representación bidimensional, (b) Representación tridimensional de la imagen (a)

#### 4.5.1 Funciones de Máxima y Mínima:

Una imagen puede tener múltiples regiones máximas o mínimas pero sólo un máximo y mínimo global. Determinar las cimas o valles en una imagen puede ser usada para crear marcadores que

pueden ser usados para la reconstrucción morfológica, por ejemplo para la segmentación a través de la transformada de Watershed. La figura 4.13 muestra este concepto en 1-dimensión.

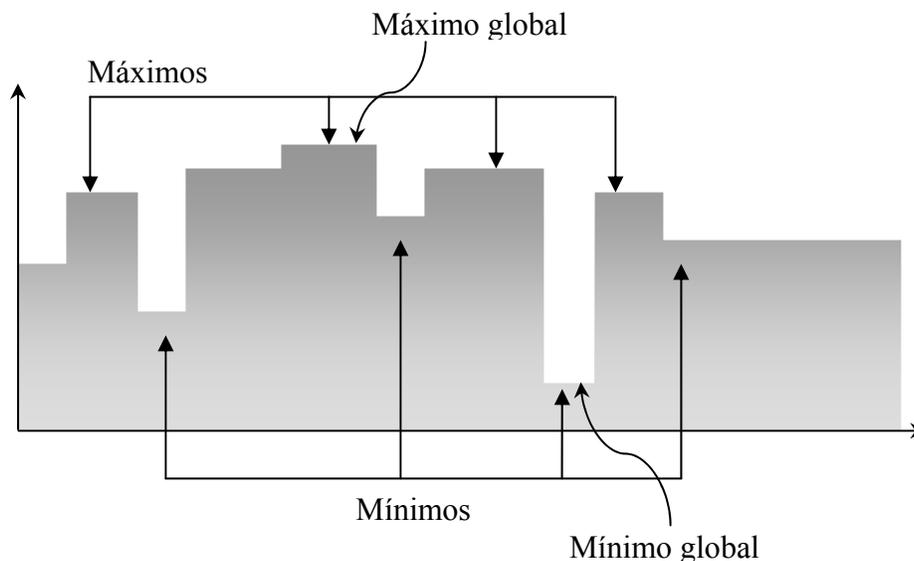


FIGURA 4.13 Valores de máximos y mínimos regionales en 1 dimensión

En una imagen, cada pequeña fluctuación de la intensidad representa una región máxima o mínima. Para el procesamiento de segmentación es importante encontrar los máximos o mínimos significativos y no los máximos o mínimos demasiado pequeños, causados por la textura de fondo o el ruido de la imagen.

Para remover los máximos y mínimos menos significativos, pero reteniendo los más significativos, se utilizan las funciones de MATLAB, `'imhmax'` o `'imhmin'`. Con estas funciones, se puede especificar un criterio de contraste o un nivel de umbral  $h$ , el cual elimina todos los máximos cuyo nivel es menor que  $h$  así como un mínimo que sea mayor que  $h$ . Para calcular los niveles mínimos en una imagen se utiliza la función `'imiposemin'`. La función `'imiposemin'` utiliza la reconstrucción morfológica para eliminar todos los mínimos de la imagen, excepto los especificados.

En la figura 4.14 se simula los niveles de gris en una imagen, en este caso en la posición (2,2) y en las posiciones (4,4), (4,5), (5,4) y (5,5) se encuentran los valores mínimos de la imagen. La característica es que estos mínimos son globales y no locales.

Imagen =

	1	2	3	4	5
1	8	8	8	8	8
2	8	<b>3</b>	5	4	8
3	8	5	5	5	8
4	8	5	7	<b>2</b>	<b>2</b>
5	8	8	8	<b>2</b>	<b>2</b>

FIGURA 4.14 Representación de una imagen en sus niveles de gris

#### 4.5.1.1 Creando un marcador de imagen:

Para obtener los valores mínimos de la imagen, se utiliza un “*marcador de imagen*” que señala los valores mínimos de acuerdo al número de píxeles vecinos que se desea minimizar. Para esto se utiliza la función ‘*imextendedmin*’, de MATLAB. En consecuencia, se obtiene una imagen binaria que muestra la posición de los valores mínimos globales (figura 4.15).

```
marcador = imextendedmin(imagen,1)
```

Marcador =

	1	2	3	4	5
1	0	0	0	0	0
2	0	<b>1</b>	0	0	0
3	0	0	0	0	0
4	0	0	0	<b>1</b>	<b>1</b>
5	0	0	0	<b>1</b>	<b>1</b>

FIGURA 4.15 Cálculo de los mínimos globales

#### 4.5.1.2 Aplicando las marcas a la imagen:

Una vez que se ha usado ‘*imextendedmin*’ para crear una nueva mínima de la imagen en los puntos mínimos, se aprecia como ‘*imimposemin*’ modifica los valores de píxeles específicos por

el marcador de la imagen. ‘*Imimposemin*’ también modifica los valores de todos los otros píxeles en la imagen (figura 4.16).

$$I = \text{imimposemin}(\text{imagen}, \text{marcador})$$

$$I =$$

	1	2	3	4	5
1	9	9	9	9	9
2	9	0	6	6	9
3	9	6	6	6	9
4	9	6	8	0	0
5	9	9	9	0	0

FIGURA 4.16 Resultado de la aplicación de la imposición de los mínimos

La figura 4.17 muestra en 1-dimensión como ‘*imimposemin*’ modifica la imagen de la segunda fila de la figura 4.14.

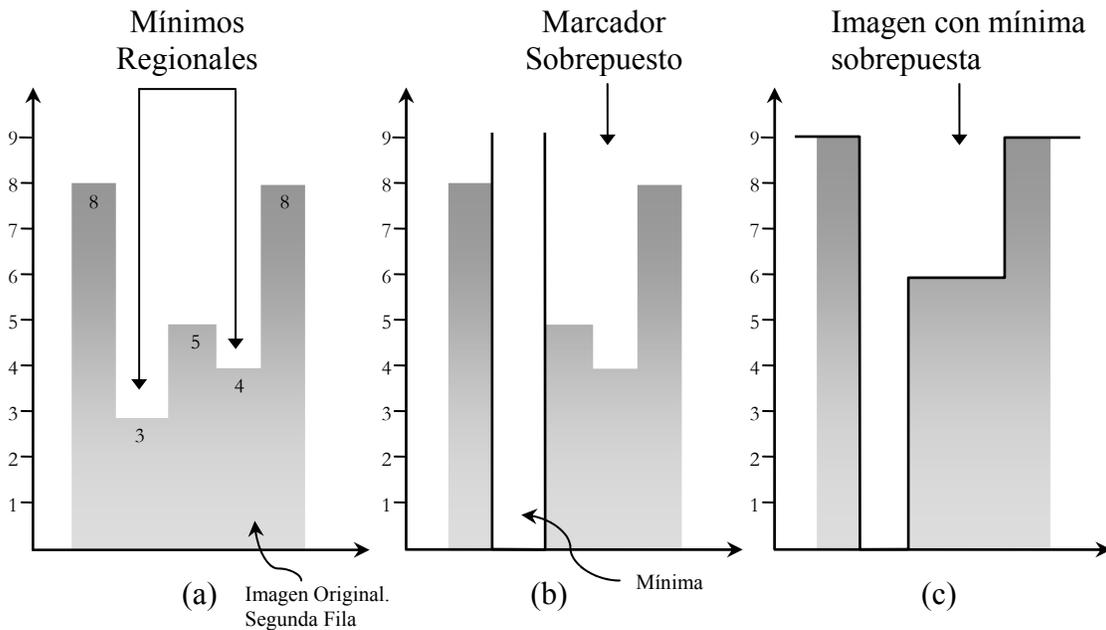


FIGURA 4.17 (a) Niveles de gris de la imagen original, (b) Marcador sobrepuesto en la imagen original, (c) Imagen resultante luego de la imposición de la mínima

La figura 4.18a muestra la representación tridimensional de una sección de BAM-5; en esta imagen se nota la gran cantidad de rugosidades producto de las variaciones en los niveles del gris.

En la figura 4.18b se muestra la aplicación de la imposición de la mínima, tal como se aplicó en la figura 4.16, se asignaron los valores mínimos a cero.

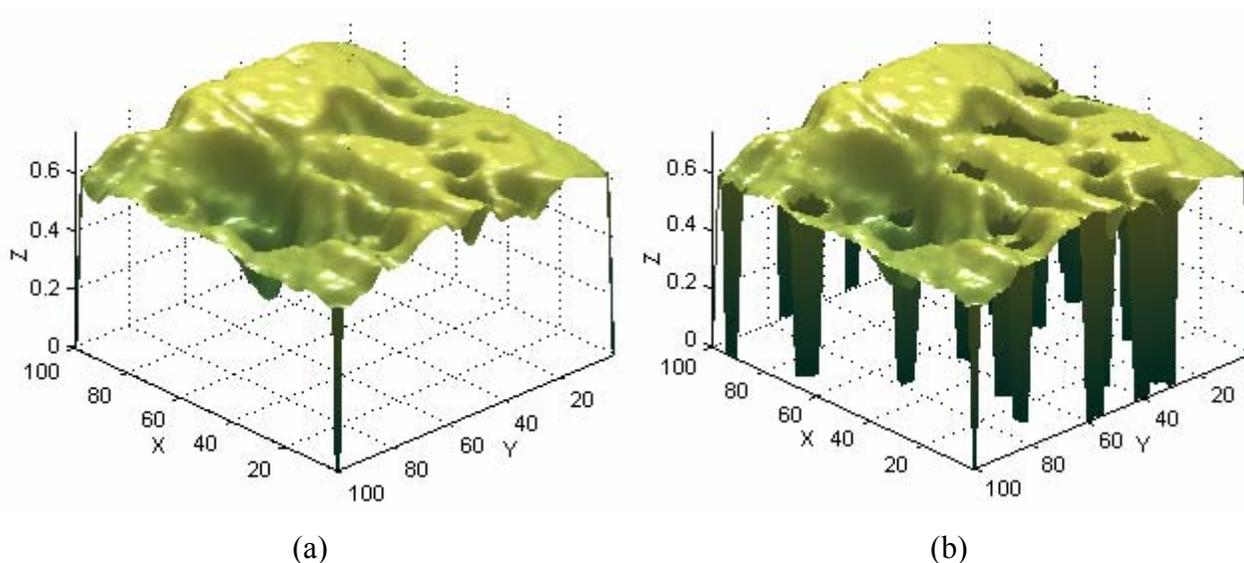


FIGURA 4.18 (a) Representación tridimensional de una sección del BAM-5, (b) Representación tridimensional de la imposición de la mínima sobre (a)

#### 4.5.2 Resumen de la aplicación de la imposición de los mínimos

En la figura 4.19 se presenta un cuadro completo del proceso de corte y asignación de la mínima; en la figura 4.19a se muestra la imagen binaria libre de la mayor parte del ruido, producto de la limpieza de la matemática morfológica; luego en la figura 4.19b se muestra la imagen con las fallas hipotéticas copiadas de la imagen original. Se observa en la figura 4.19c, el cálculo de los mínimos y finalmente, la figura 4.19d presenta la imposición de los mínimos.

Son evidentes las diferencias entre la figura 4.19b con respecto a la figura 4.19d, de este modo, se facilita la segmentación a través de la transformada de Watershed, por dos razones: primero, se cuenta con las regiones con fallas hipotéticas que deben ser analizadas; segundo, el proceso de imposición de mínimos permite a la transformada de Watershed evitar la sobsegmentación debido a la construcción del algoritmo.

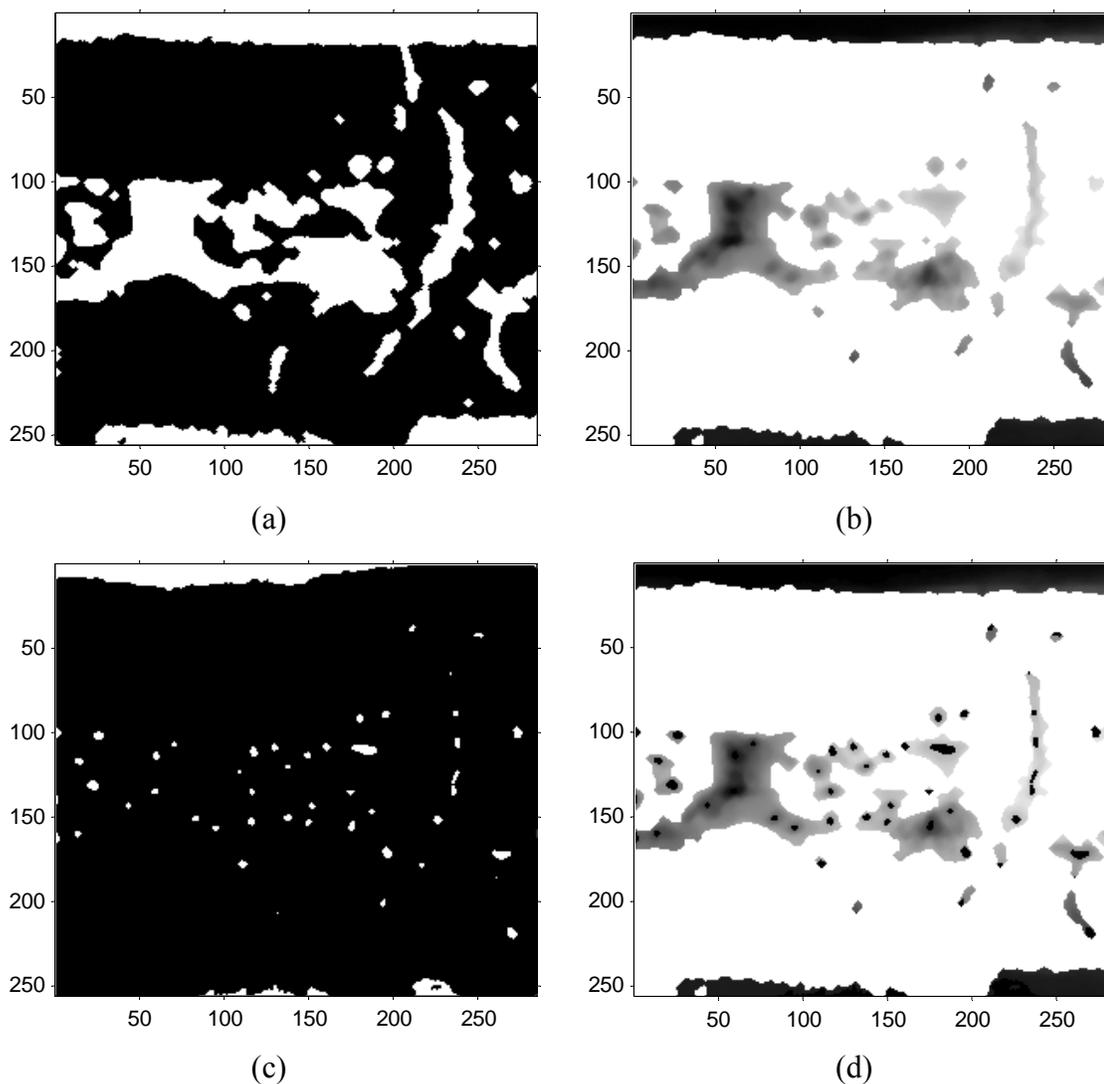
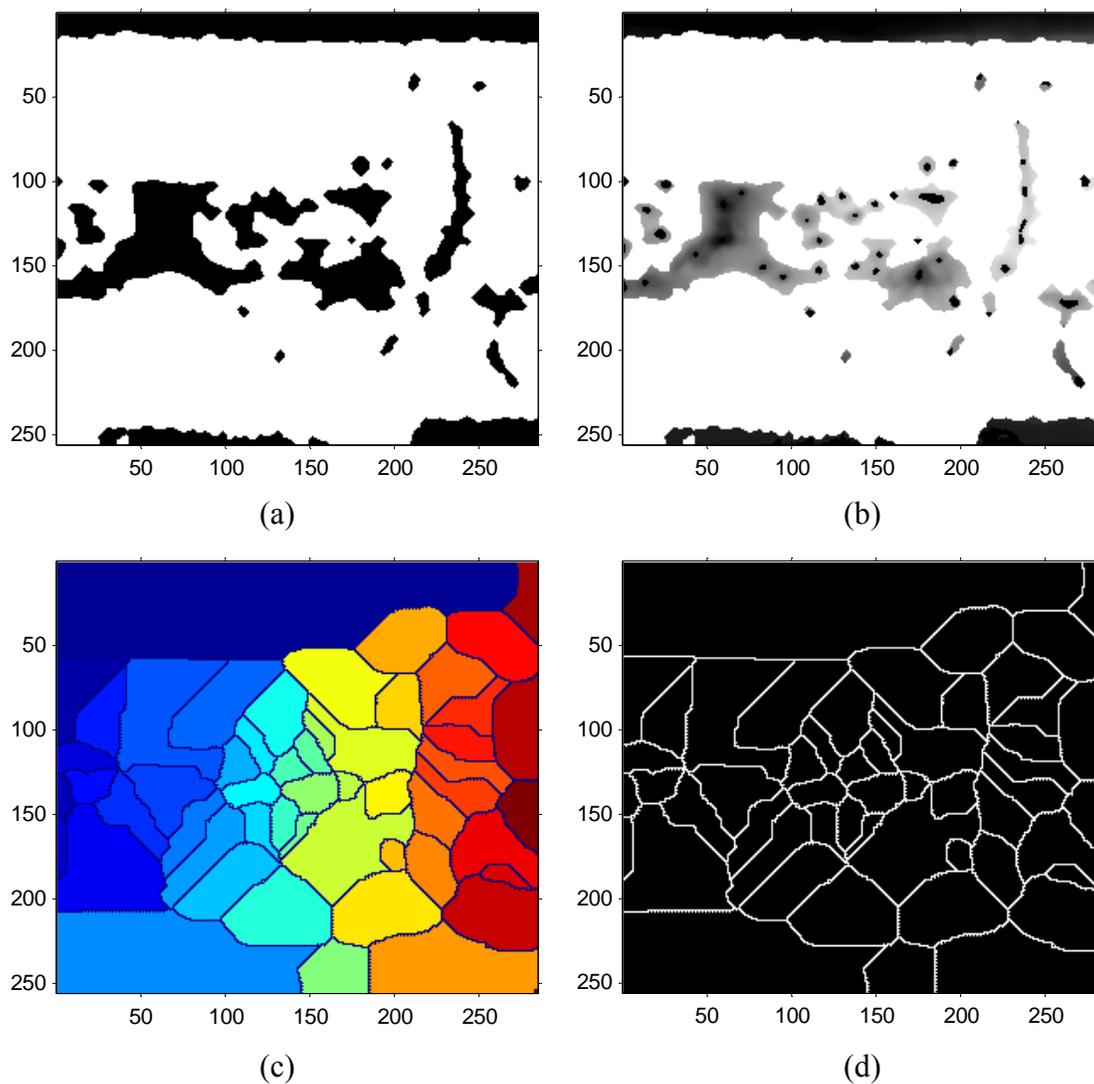


FIGURA 4.19 (a) Imagen binaria, (b) Corte de secciones de la imagen binaria sobre la imagen original, (c) Calculo de los puntos mínimos de la imagen recortada, (d) Imposición de los mínimos sobre la imagen (b)

## 4.6 APLICACIÓN DE LA TRANSFORMADA DE WATERSHED

En la sección 3.5.8 se propone un método para evitar la sobresegmentación. La idea consiste en modificar los valores mínimos de la imagen original y luego aplicar la transformada de Watershed; este procedimiento se denomina “*Homotopy modification*”. La primera etapa del

proceso se observa en la figura 4.20b, en la cual se han modificado los valores mínimos de la imagen; a continuación se aplica la transformada de Watershed sobre la figura 4.20b. El resultado se presenta en la figura 4.20c.



*FIGURA 4.20 (a) Imagen binaria negada, (b) Imagen con imposición de los mínimos, (c) Separación de regiones con Watershed, (d) Líneas de Watershed*

La figura 4.20d presenta una imagen binaria que se suma a la figura 4.20a, de esta manera, las estructuras binarias son segmentadas producto del corte binario generado a partir de la líneas de división de Watershed.

En la figura 4.21a, se observa el resultado binario de la suma entre la figura 4.20a y la figura 4.20d. Es claro notar que sólo se reflejan las líneas que cortan las estructuras, ya que en las zonas donde no hay fallas, las líneas de corte no aparecen. A continuación se determinan los bordes de la figura 4.21a y se superponen sobre la imagen original, dando como resultado la figura 4.21b.

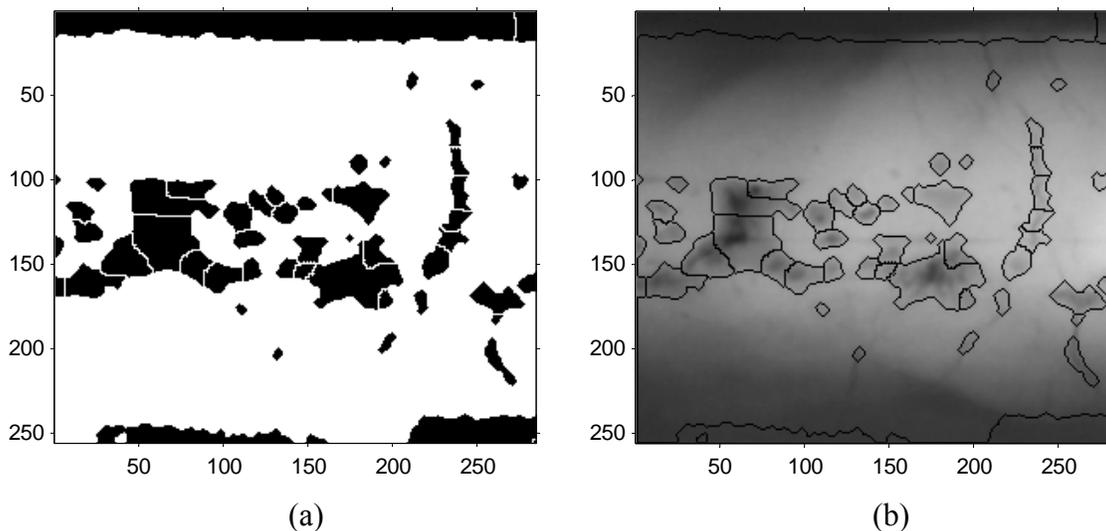


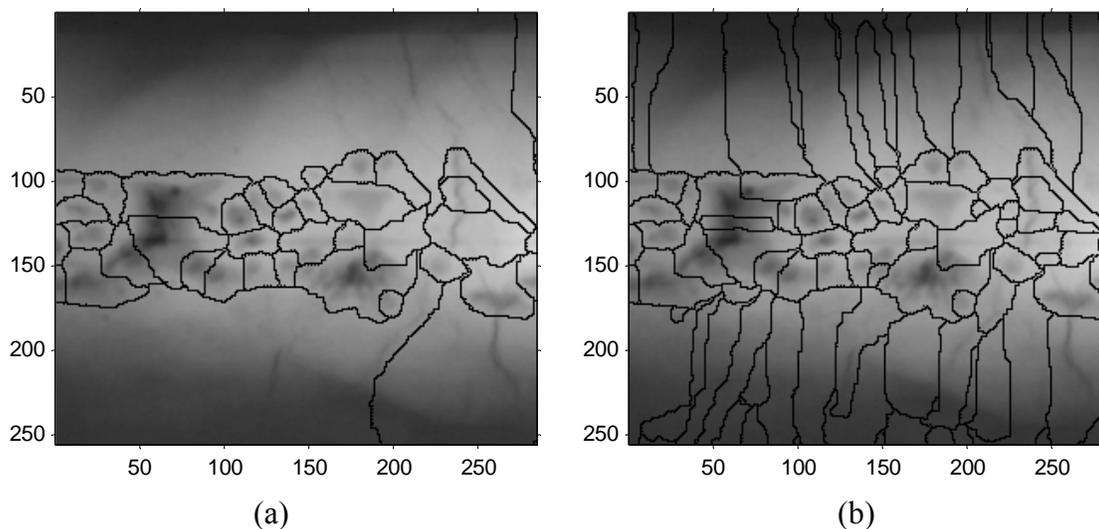
FIGURA 4.21 (a) Imagen binaria segmentada, (b) Imposición de los cortes sobre la imagen original

Una de las ventajas de aplicar la transformada de Watershed sobre las estructuras factibles de fallas, se debe a que sólo se segmentan estas regiones y no se considera las zonas adyacentes a las fallas, las cuales han sido descartadas en el proceso bottom-hat.

Además, al aplicar la modificación de los mínimos (*Homotopy modification*), se puede regular la cantidad de regiones a segmentar, al determinar la cantidad de píxeles que componen la mínima; de este modo, a medida que el valor de los mínimos crece, la cantidad de regiones segmentadas a través de Watershed disminuye.

Sin el proceso anterior, la segmentación resultante genera una división errónea, por ejemplo, si se realiza el proceso de modificación de los mínimos directamente sobre la imagen original; el resultado entrega una segmentación con respecto a la totalidad de la imagen y no sobre las regiones con fallas, generando el resultado que se observa en la figura 4.22a.

En el caso de aplicar la transformada de Watershed sobre la imagen original, sin el procesamiento de corte y sin la modificación de los mínimos, se genera una sobresegmentación, la cual no permite determinar las regiones con fallas, como tampoco determinar su ubicación; este último caso se observa en la figura 4.22b.



*FIGURA 4.22 (a) Segmentación de Watershed sin la separación de regiones, (b) Segmentación de Watershed sin el procesamiento de “Homotopy modification”*

En los dos casos anteriores, se ha considerado aplicar el procedimiento de reducción de ruido, de tal forma que las comparaciones se inicien desde un mismo punto. Es importante destacar que las diferencias entre la figura 4.22a y la figura 4.22b se deben al procedimiento de modificación de los mínimos; esta estrategia permite reducir la sobresegmentación y mejora la calidad de la segmentación.

#### **4.6.1 Resumen del proceso de segmentación**

El proceso de segmentación propuesto utiliza una combinación de técnicas de procesamiento digital, las cuales han sido seleccionadas a partir de pruebas y análisis experimentales; este desarrollo se presenta en la figura 4.23. Cada etapa se ha analizado en forma independiente y también en forma global; esto ha permitido que se estudiaran diferentes variantes y estrategias.

Dentro de las variantes con respecto al ruido, se analizó el filtro Gaussiano y el filtro promedio. Se verificó que el filtro de la mediana disminuye el nivel de ruido sin afectar la calidad de los bordes. Por otra parte el filtro bottom-hat ha permitido obtener la mayoría de las fallas al separarlas del fondo; esta característica determina en gran medida la calidad de la segmentación debido al posterior análisis de las fallas hipotéticas.

En el proceso de detección de bordes, se ha seleccionado el método de umbralización binaria, ya que permite obtener estructuras cerradas y sólo requiere de un proceso de eliminación del ruido a través de la cerradura, en cambio, se demostró la dificultad que tiene el método de Canny para cerrar sus bordes a través de métodos morfológicos.

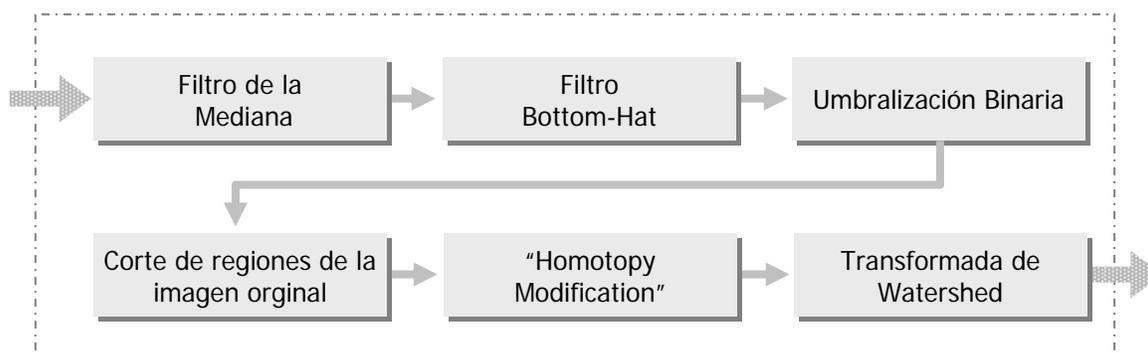


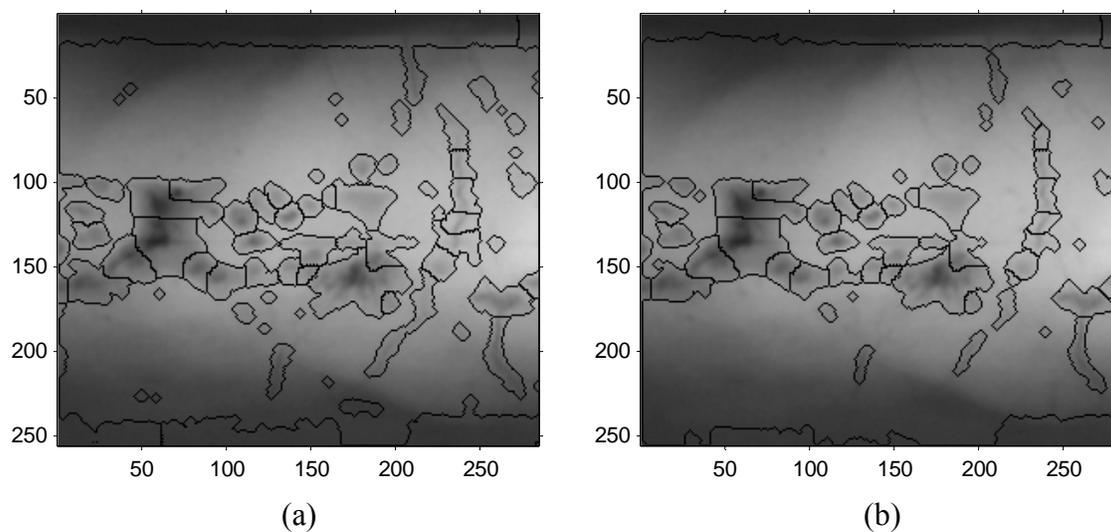
FIGURA 4.23 Resultado del proceso de segmentación propuesto

Luego, en el proceso de corte de secciones, se ha verificado la utilidad que presenta copiar las regiones de la imagen original, en comparación con la transformada de la distancia, ya que esta última sólo simula las estructuras de las fallas, en cambio, si se utilizan los mismos píxeles de la imagen original, se obtiene una segmentación con mayor precisión.

La modificación de los mínimos es parte de la estrategia llamada “*Homotopy modification*”, que ha permitido evitar la sobsegmentación, y generar una segmentación más precisa, sin embargo, es importante determinar el número de píxeles que compone el mínimo, ya que una variación en ella permite generar una mayor o menor cantidad de fallas hipotéticas. La última herramienta utilizada es la transformada de Watershed; esta técnica en combinación con la modificación de los mínimos permite segmentar las regiones interiores a las estructuras, ya que la segmentación

externa se ha realizado en el proceso de umbralización binaria. El proceso general de la segmentación, en especial la etapa de la umbralización binaria, ha permitido generar la mayoría de las estructuras y sus bordes. Se ha demostrado que la transformada de Watershed por sí sola no genera la segmentación de las fallas, ya que segmenta la imagen por completo (figura 4.22), es por ello la importancia del proceso anterior a su aplicación.

En la figura 4.24, se observan las diferencias entre la aplicación del umbral en el proceso de segmentación. A medida que el umbral aumenta, disminuyen las regiones segmentadas, y además estas tienden a tener una menor área interna. Otras variables del proceso influyen en la cantidad y forma de las regiones, tales como el filtro bottom-hat, la elección del punto de corte, además de las operaciones de dilatación y erosión. Sin embargo los efectos en la modificación de las variables generan resultados distintos; en algunos casos este cambio puede resultar en una segmentación imprecisa, por este motivo es importante analizar el efecto en la modificación de cada variable y como afecta el resultado final.



*FIGURA 4.24 (a) Segmentación de la imagen con umbral = 3, (b) Segmentación de la imagen con umbral = 5*

## 4.7 MÉTODOLÓGÍA DE COMPARACIÓN

Para evaluar la segmentación propuesta, se utiliza la curva ROC (Egan, 1975) la cual permite medir el rendimiento de una clasificación de dos clases. Estas clases están constituidas por el conjunto de regiones segmentadas con defecto y libre de defecto o regulares; para ello se debe determinar la prueba de ‘Sensibilidad’ y la ‘1-especificidad’:

$$S_n = \frac{VP}{VP + FN} \qquad 1 - S_p = \frac{FP}{FP + VN} \qquad (4.1)$$

Donde:  $VP$  (Verdadero Positivo), es el número de píxeles con defectos clasificados correctamente;  $VN$  (Verdadero Negativo), es el número de píxeles sin defectos clasificados como regulares;  $FP$  (Falso Positivo), es el número de píxeles regulares, clasificados como píxeles con defecto, o como falsa alarma y finalmente,  $FN$  (Falso Negativo) es el número de píxeles con defecto, clasificados como regulares. Cuando  $S_n = 1$ , significa que se ha detectado la totalidad de los defectos (en este caso, fallas de soldadura), para ello  $FN$  debe tender a cero. La relación  $1 - S_p = 0$ , significa que no se ha detectado falsas alarmas, es decir, regiones regulares que sean consideradas como fallas, para ello  $FP$  debe tender a cero. La relación entre las clases se presenta en la figura 4.25.

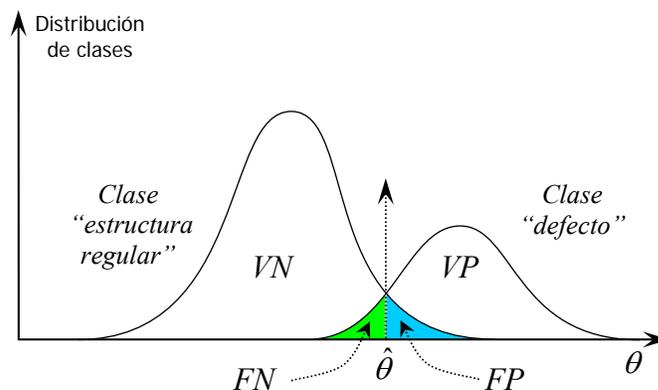


FIGURA. 4.25 Distribución de clases de las regiones segmentadas (Mery et al, 2003)

De acuerdo a la figura 4.26, cuando el área de curva se acerca a 1, la sensibilidad tiende a 1 y 1-especificidad, tiende a 0. En consecuencia, el punto donde la prueba es ideal se encuentra en la posición (0,1). A medida que el parámetro  $\hat{\theta}$  se desplaza en la curva de la figura 4.25 se genera la curva ROC de acuerdo a la elección de la prueba en distintos puntos de corte.

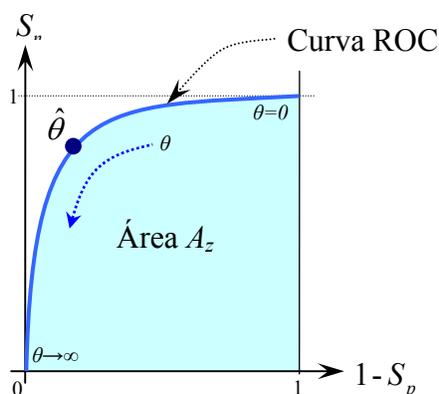


FIGURA.4.26 Curva ROC con variación de  $\theta$  (Mery et al, 2003)

La figura 4.27 presenta un ejemplo del método de comparación empleado para calcular las variables  $VP$ ,  $VN$ ,  $FP$  y  $FN$ . De esta manera, se puede calcular la ‘Sensibilidad’ y la ‘1-especificidad’, cuando se analicen los valores de cada píxel de las dos imágenes y se realice la comparación.

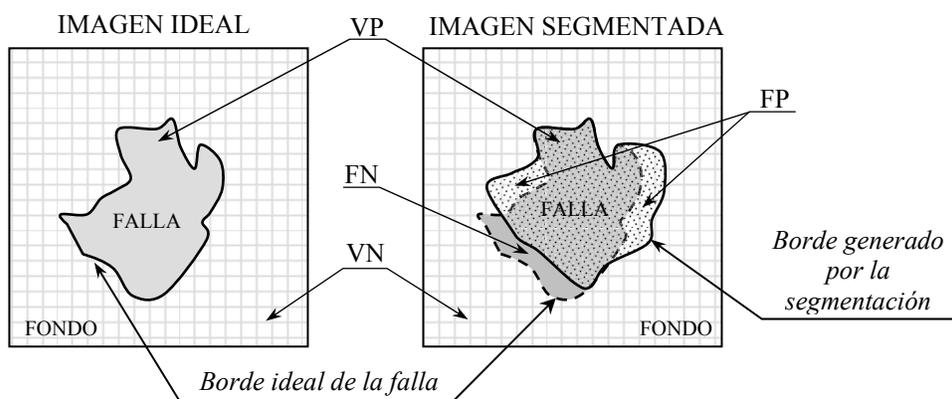


FIGURA 4.27 Representación de las diferencias entre la imagen ideal y segmentada

Para realizar el análisis entre las distintas pruebas, se debe calcular el área  $A_z$  de la curva ROC. Un área equivalente  $A_z = 1$ , significa que la segmentación ha sido la ideal, en cambio cuando  $A_z = 0.5$ , la segmentación ha sido aleatoria (Egan, 1975). El análisis de la curva ROC se realiza de acuerdo al método propuesto en (Mery & Pedreschi, 2003). La idea consiste en separar las clases de acuerdo a la comparación de la imagen segmentada con una imagen que contiene sólo las fallas reales. Tanto la imagen segmentada como la ideal son binarias y la comparación se realiza píxel a píxel.

#### 4.7.1 Selección de valores de la curva ROC

Los distintos valores de entrada del método propuesto determinan que la curva ROC no pueda ser modelada con un sólo parámetro. La modificación de los valores de entrada del algoritmo, genera un mapa de puntos en la curva ROC relativos a cada prueba. Por esta razón, para mejorar la comprensión y el cálculo del área bajo la curva, se ha implementado un algoritmo que determina los mejores valores dentro de un intervalo determinado, de este modo, se obtiene puntos de la curva separados en cada intervalo y seleccionando los valores que aumenten el área. La figura 4.28b presenta la curva que selecciona los puntos con mayor sensibilidad entre intervalos de 0.02 desde 0 a 1. Se asegura que se elija el máximo valor en ese rango al recorrer todos los puntos de las pruebas realizadas.

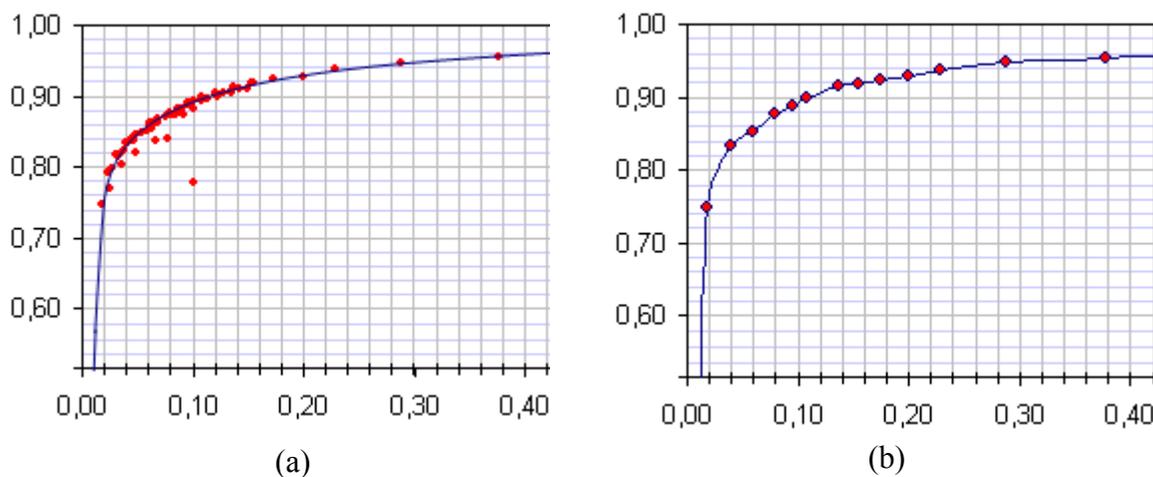


FIGURA 4.28 (a) Curva ROC de las pruebas realizadas, (b) Selección de puntos máximos de la curva ROC en intervalos de 0.02 de (a)

## **CAPÍTULO 5 EXPOSICIÓN DE RESULTADOS**

En este capítulo se exponen los resultados correspondientes al conjunto de imágenes segmentadas a través del algoritmo desarrollado en el capítulo anterior. Además se presenta la comparación entre el método de análisis de texturas desarrollado en (Mery & Berti, 2003), y el método de segmentación propuesto. La comparación entre estos no es la ideal, ya que el método de análisis de texturas incluye el proceso de segmentación a través del filtro LoG, extracción de características y clasificación. En cambio, el método propuesto realiza sólo la fase de segmentación, pudiendo tener una mejora en su rendimiento si se incluyen las siguientes etapas de la AVI (extracción de características y clasificación). Una característica adicional que tiene el método desarrollado, es el menor nivel de regiones segmentadas en comparación con el método LoG; este último utiliza la combinación del filtro Gaussiano para suavizar la imagen y disminuir los niveles de ruido, luego se utiliza el operador Laplaciano para generar una imagen binaria que contenga los bordes de las fallas determinada por el análisis de cruces por cero a través de la segunda derivada. El número de “fallas hipotéticas” queda determinado por las regiones cerradas que encuentre el filtro LoG, siendo considerablemente mayor que el filtro propuesto.

El objetivo de tener una menor cantidad de regiones segmentadas se debe a la disminución en tiempo de procesamiento para las posteriores etapas de la AVI. Es importante para el proceso el tipo de región que se analiza, por lo tanto, se requiere cumplir dos objetivos, tener una menor cantidad de regiones segmentadas y a la vez una baja cantidad de falsas alarmas. En este sentido, el proceso de segmentación debe ser lo más preciso posible en detectar las fallas reales.

El algoritmo posee un conjunto de parámetros de entrada que deber ser adaptado a cada imagen para obtener una segmentación que se aproxime a la ideal. El estudio de las imágenes de prueba, no debe ser exclusivo para el conjunto que se analiza, por este motivo, todas las imágenes se someten al mismo conjunto de parámetros con el propósito de construir una curva ROC general sobre todas las imágenes del estudio. De esta manera, se obtiene un conjunto de parámetros óptimos que se pueda aplicar a cualquier otra imagen que no se encuentre en este análisis. Este

punto no necesariamente representa el óptimo para cada imagen, sin embargo, generalmente se aproxima a él.

En el estudio se ha determinado entre 65 y 75 combinaciones por cada imagen, y de estos resultados se ha seleccionado los puntos que maximicen la curva, separados en intervalos de 0.02 en 1-especificidad. En algunos casos, existen dos puntos que se aproximan al valor óptimo de la curva ROC, es por esto que en todas imágenes se ha calculado los dos mejores valores de la curva. Además se ha calculado el área bajo la curva  $A_z$ , ya que este valor permite medir la calidad en la separación de las clases y el rendimiento general de la segmentación generada.

La tabla 5.1 presenta un resumen de las imágenes analizadas en el estudio; en la columna del “Numero de regiones ideales”, se presenta el número de regiones reales que hay que segmentar; en este punto hay que reiterar que el análisis de la sensibilidad y la 1-especificidad se realiza píxel a píxel, utilizando el método propuesto en (Mery & Pedreschi, 2003); debido a esta razón, los resultados difieren para el caso del estudio presentado en (Mery & Berti, 2003), en el cual se analizan las regiones como conjunto y no píxel a píxel.

*TABLA 5.1 Resumen de las imágenes segmentadas y sus mejores valores de sensibilidad, 1-especificidad, Área  $A_z$  y tiempo de procesamiento*

	Nombre de la imagen	Tamaño de la imagen en píxeles	Número de regiones ideales	Número de regiones segmentadas por el proceso	Mejores puntos de la curva ROC		Tiempo [s] de cálculo	Megapíxel x Seg	$A_z$
					Sensibilidad	1-Especificidad			
1	BAM5.tif	3512x366	273	495	0.9004	0.0762	30.48	0.0422	93.08%
2	12R_M.tif	4919x835	36	933	0.9693	0.0387	94.73	0.0434	98.03%
3	13R_M.tif	4125x686	62	520	0.9038	0.0747	56.66	0.0499	95.22%
4	22R_M.tif	4992x646	23	678	0.9421	0.0429	74.00	0.0436	97.44%
5	28R_M.tif	4968x527	47	1062	0.9108	0.0510	58.13	0.0450	94.34%
6	31R_M.tif	4968x756	11	179	0.9951	0.058	64.84	0.0579	99.52%
7	39R_M.tif	4973x745	90	1110	0.8768	0.0786	83.45	0.0444	94.36%
8	40R_M.tif	4964x775	30	731	0.8228	0.0374	91.84	0.0419	91.31%
9	106R_M.tif	4981x494	97	836	0.8124	0.0617	51.76	0.0475	89.90%
10	107R_M.tif	4953x1091	59	2461	0.8065	0.1096	161.42	0.0335	89.41%

La figura 5.1 presenta un gráfico que relaciona el área  $A_z$  y la velocidad de procesamiento, medida como el número de megapíxeles procesados por segundo. El análisis del gráfico permite verificar que a medida que aumenta la velocidad del procesamiento, también lo hace el área  $A_z$ . Esto se debe a que la velocidad de procesamiento está en relación con el número de regiones a segmentar y, además con el nivel de ruido en la imagen. A medida que aumenta el ruido, existen una mayor cantidad de regiones que procesar y analizar, lo cual incrementa el tiempo de procesamiento.

Este hecho se ve reflejado en el caso 10 de la tabla 5.1, donde el área bajo la curva  $A_z = 89.41$  tiene 2461 regiones segmentadas, en cambio, en el caso 6 el área  $A_z = 99.52$ , genera 179 regiones. Los casos intermedios tienen variaciones entre ellos, pero la tendencia general indica que la influencia del ruido afecta al rendimiento de la segmentación, como también el tiempo de procesamiento.

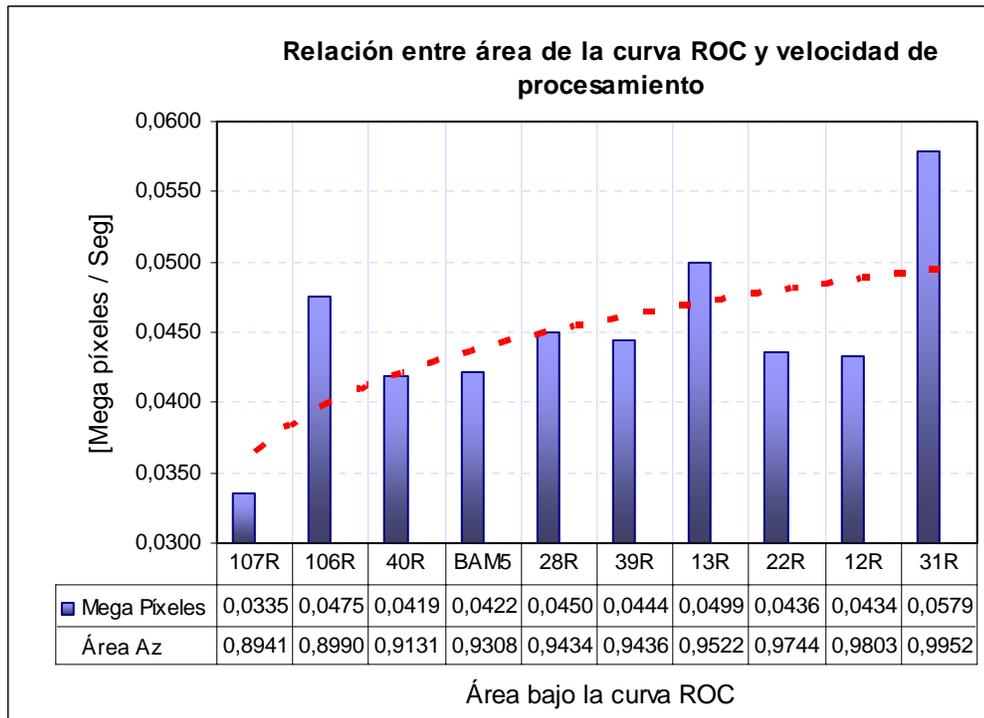


FIGURA 5.1 Relación entre área  $A_z$  y velocidad de procesamiento (Megapixel x segundo)

## 5.1 ANÁLISIS DE LAS IMÁGENES DEL BAM

A continuación se presenta un detalle de las imágenes listadas en la tabla 5.1, indicando el área de la curva ROC y los mejores parámetros de la curva ROC generada, además de los tiempos de ejecución. En el caso de la imagen BAM-5 se presenta una sección de la segmentación generada; el resto de las imágenes segmentadas se encuentra en el Apéndice B.

### 5.1.1 Análisis de la imagen BAM5.tif

En la figura 5.2 se presenta una sección ideal y segmentada de la imagen BAM-5, siendo el primer parámetro de la tabla 5.2 el utilizado para completar el proceso de segmentación. Una de las principales diferencias entre las dos imágenes se encuentra en el tamaño de las regiones segmentadas.

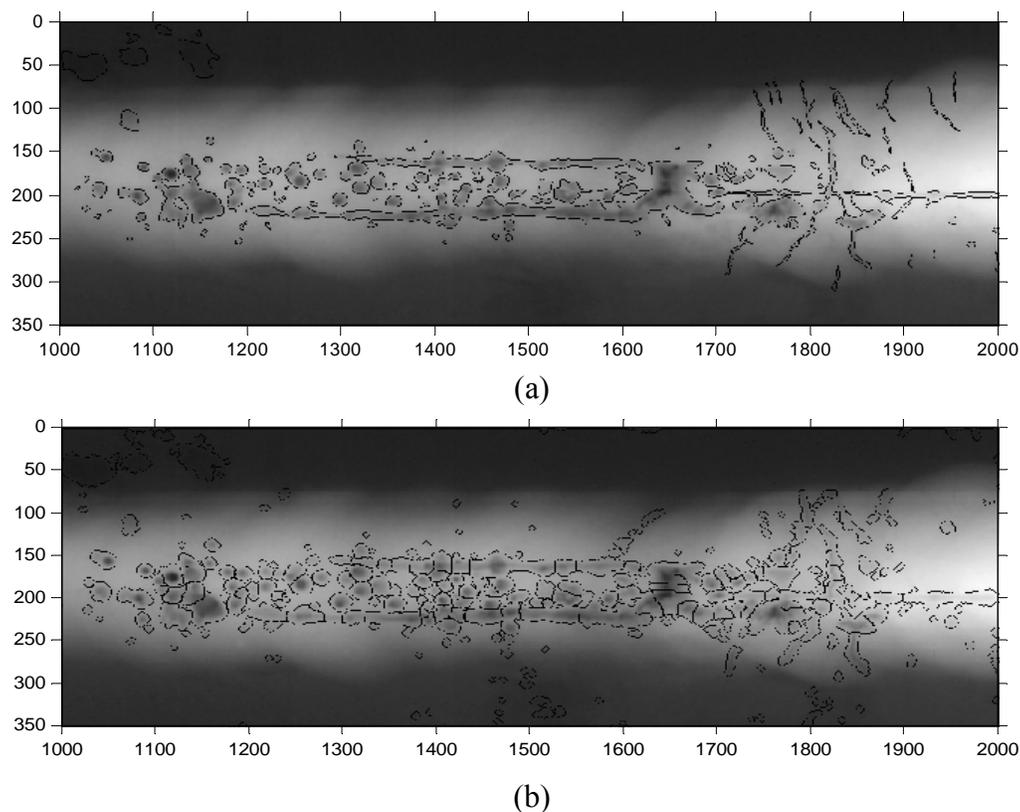


FIGURA 5.2 (a) Sección de la imagen BAM-5 ideal, (b) Sección de la imagen BAM-5 segmentada con el proceso propuesto

Se observa en la figura 5.2b como el tamaño de las estructuras es mayor que la segmentación ideal. Esto tiene la ventaja de tener una menor cantidad de *FN* (fallas clasificadas como estructuras regulares), pero aumenta el número de *FP* (estructuras regulares clasificadas como fallas).

La figura 5.3 tiene un área  $A_z = 93.08\%$  y su mejor punto operacional tiene 0.9004 de sensibilidad y 0.0762 de 1-especificidad. El siguiente punto tiene 0.9046 de sensibilidad y 0.0972 de 1-especificidad (tabla 5.2). En este caso, la aplicación del dilatador aumenta las falsas alarmas, razón por la cual no se ha utilizado. Otro factor de relevancia es la baja cantidad de regiones encontradas con este método. Con el método LoG, la cantidad de regiones se triplica.

TABLA 5.2 Mejores puntos de la curva ROC de la imagen BAM5.tif

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	3x3	26	18	No	495	0.9004	0.0762	30.484
2	3x3	30	27	No	415	0.9046	0.0972	32.563

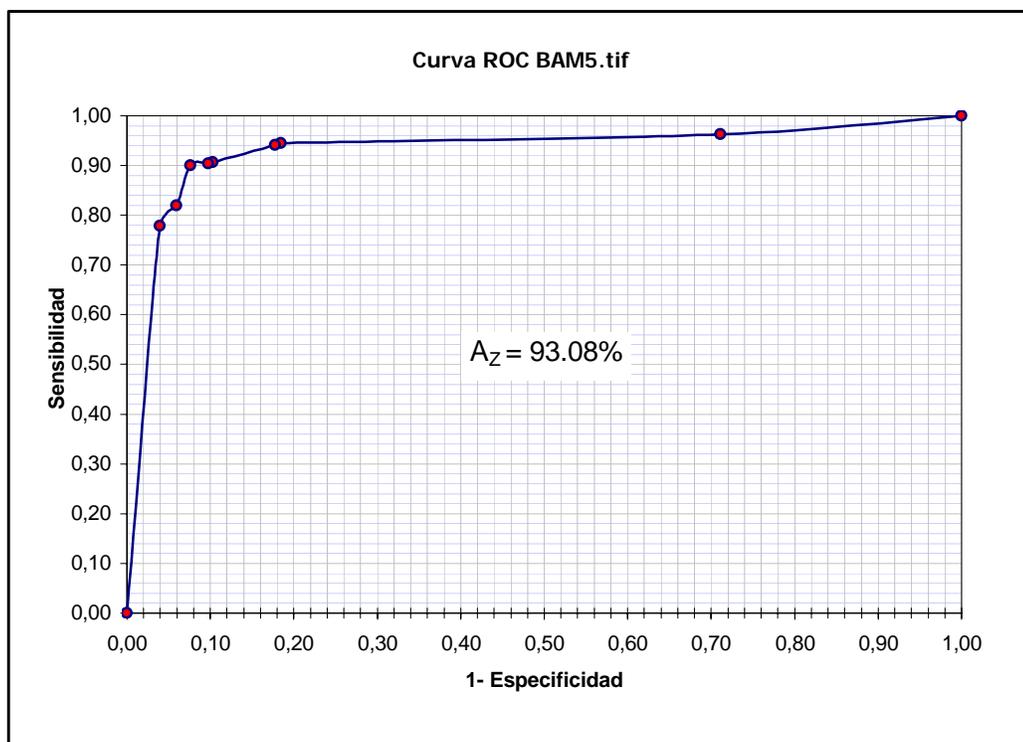


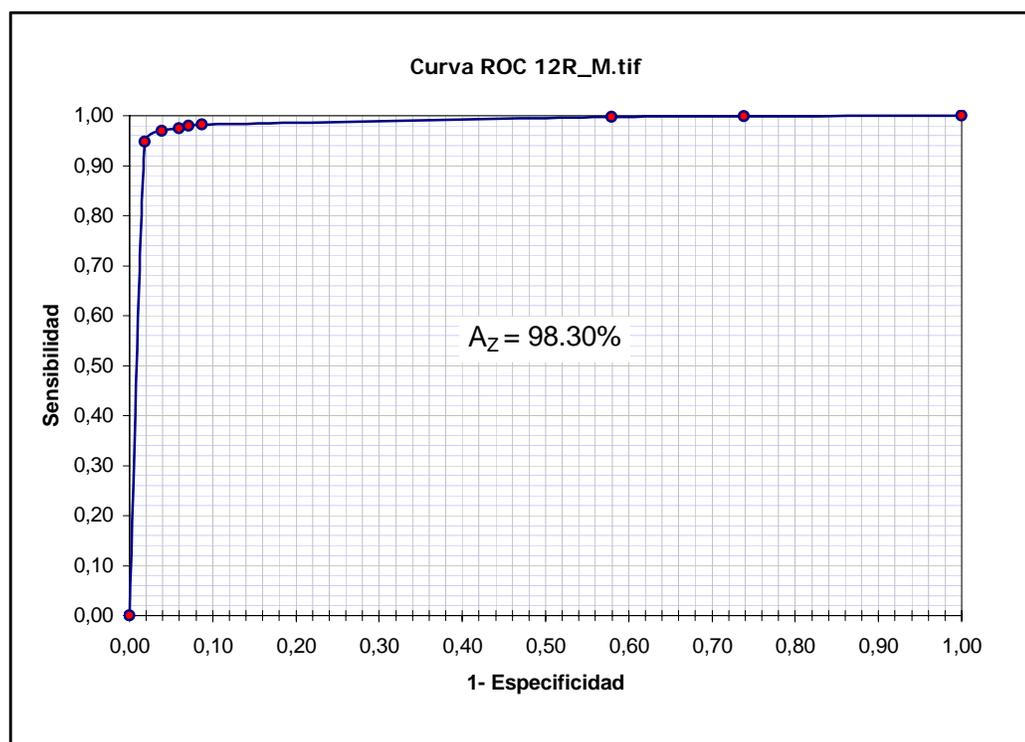
FIGURA 5.3 Curva ROC de la imagen BAM5.tif

### 5.1.2 Análisis de la imagen 12R\_M.tif

La figura 5.4 tiene un área  $A_z = 98.30\%$  y su mejor punto operacional tiene 0.9693 de sensibilidad y 0.0387 de 1-especificidad. El siguiente punto tiene 0.9483 de sensibilidad y 0.0183 de 1-especificidad (tabla 5.3). Es importante notar que a medida que el tamaño de la mediana aumenta, disminuye la cantidad de regiones debido a que distintas regiones de menor tamaño se difuminan con su entorno. En este caso el aumento de 1x1 a 4x4 en la máscara de la mediana, ha disminuido el número de regiones como también el porcentaje de falsas alarmas.

*TABLA 5.3 Mejores puntos de la curva ROC de la imagen 12R\_M.tif*

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	1x1	32	27	Si	933	0.9693	0.0387	94.734
2	4x4	30	9	Si	666	0.9483	0.0183	74.719



*FIGURA 5.4 Curva ROC de la imagen 12R\_M.tif*

### 5.1.3 Análisis de la imagen 13R\_M.tif

La figura 5.5 tiene un área  $A_z = 95.22\%$  y su mejor punto operacional tiene 0.9038 de sensibilidad y 0.0747 de 1-especificidad. El siguiente punto tiene 0.8828 de sensibilidad y 0.0545 de 1-especificidad (tabla 5.4). En este caso la imagen estudiada tiene una gran cantidad de ruido, por este motivo el tamaño de la mediana es muy superior a la imagen anterior; además esto ha permitido que se genere una menor cantidad de regiones segmentadas. La única diferencia entre estos dos puntos, lo hace el tamaño del disco del filtro bottom-hat. En este caso la disminución del tamaño del disco ha permitido disminuir la cantidad de regiones, como el grado de sensibilidad y de 1-especificidad.

TABLA 5.4 Mejores puntos de la curva ROC de la imagen 13R\_M.tif

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	8x8	24	27	Si	520	0.9038	0.0747	56.657
2	8x8	20	27	Si	454	0.8828	0.0545	52.344

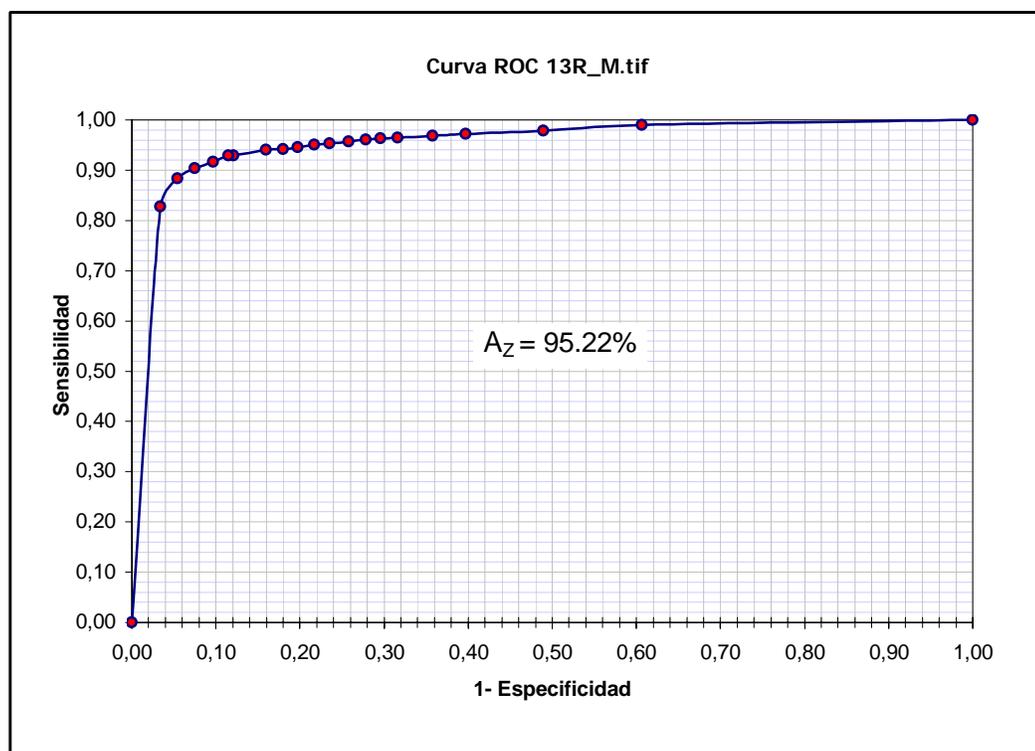


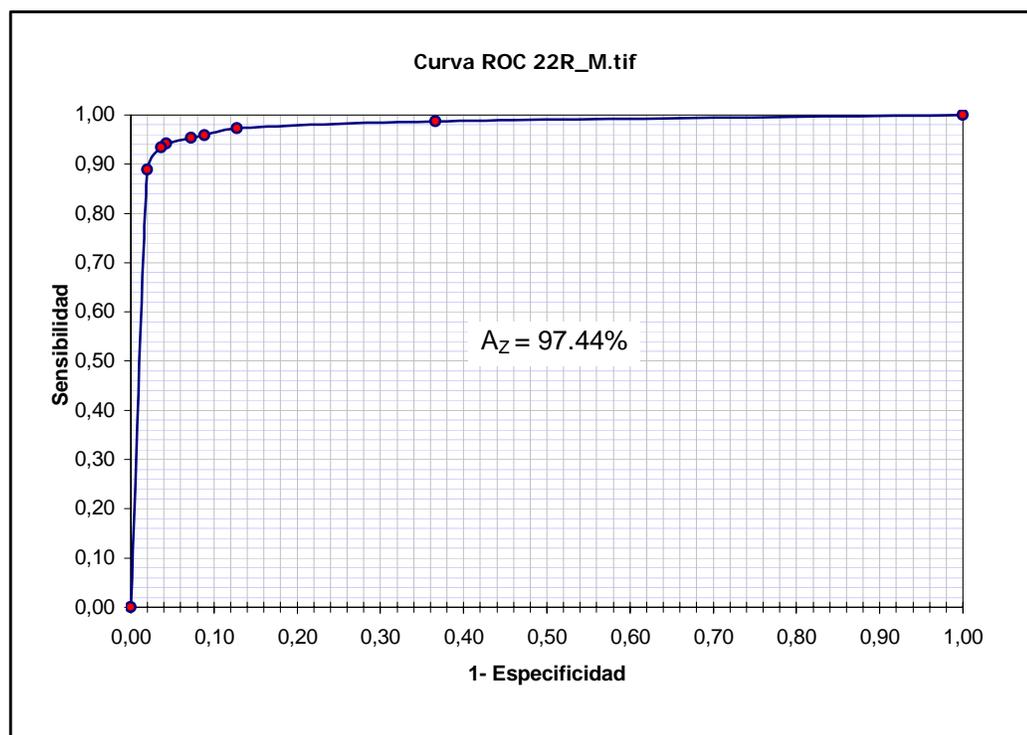
FIGURA 5.5 Curva ROC de la imagen 13R\_M.tif

### 5.1.4 Análisis de la imagen 22R\_M.tif

La figura 5.6 tiene un área  $A_z = 97.44\%$  y su mejor punto operacional tiene 0.9421 de sensibilidad y 0.0429 de 1-especificidad. El siguiente punto tiene un 0.9343 de sensibilidad y 0.0365 de 1-especificidad (tabla 5.5). Esta imagen tiene una menor cantidad de fallas que la anterior además de un bajo nivel del ruido, es por ello que el tamaño de la mediana es menor a los tamaños de otras imágenes. Al igual que en los casos anteriores, la disminución de regiones se debe al incremento en el tamaño de la mediana.

*TABLA 5.5 Mejores puntos de la curva ROC de la imagen 22R\_M.tif*

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	1x1	32	27	Si	678	0.9421	0.0429	74.000
2	2x2	32	27	Si	574	0.9343	0.0365	70.375



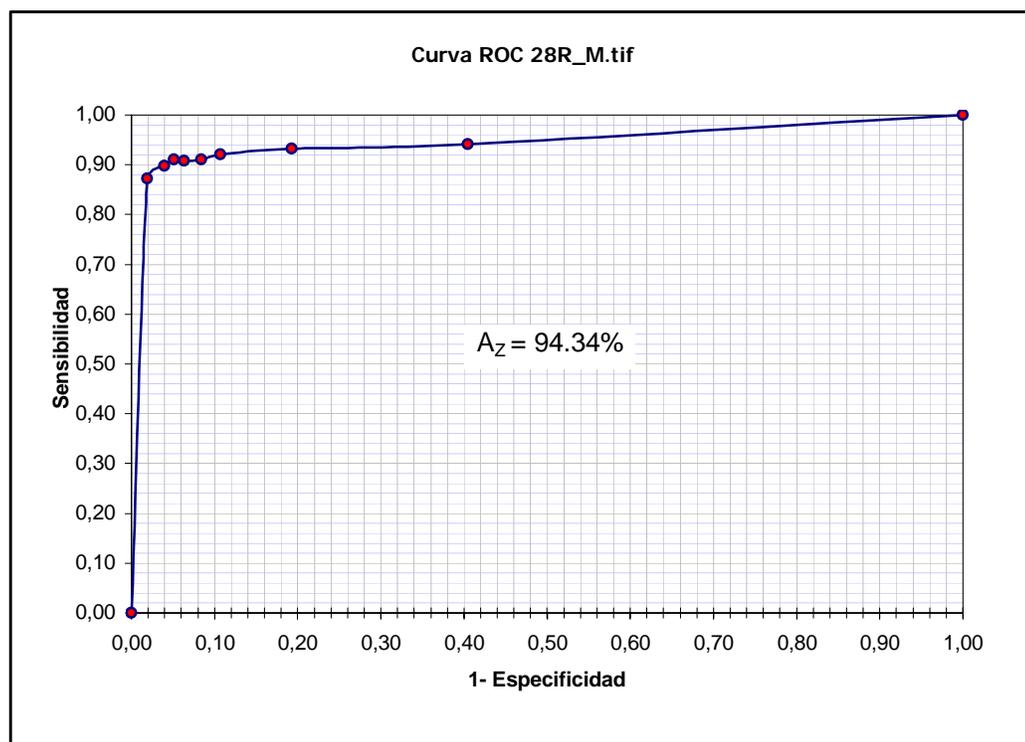
*FIGURA 5.6 Curva ROC de la imagen 22R\_M.tif*

### 5.1.5 Análisis de la imagen 28R\_M.tif

La figura 5.7 tiene un área  $A_z = 94.34\%$  y su mejor punto operacional tiene 0.9108 de sensibilidad y 0.0510 de 1-especificidad. El siguiente punto tiene 0.8983 de sensibilidad y 0.0395 de 1-especificidad (tabla 5.6). Este caso es distinto a los anteriores; la mayor cantidad de regiones se debe a que sólo se han eliminado las regiones menores a 9 píxeles, en cambio en el segundo punto se han eliminado las regiones menores a 27 píxeles; debido a esto ha disminuido las regiones segmentadas a 521.

*TABLA 5.6 Mejores puntos de la curva ROC de la imagen 28R\_M.tif*

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	2x2	30	9	Si	1062	0.9108	0.0510	58.125
2	2x2	32	27	Si	521	0.8983	0.0395	58.844



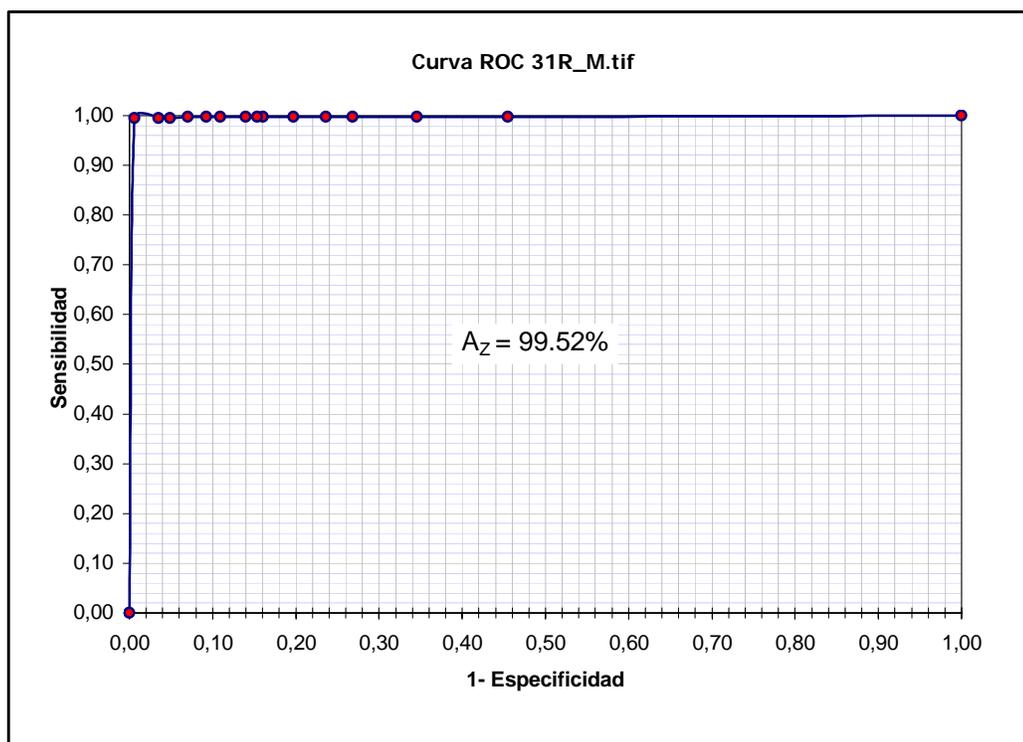
*FIGURA 5.7 Curva ROC de la imagen 28R\_M.tif*

### 5.1.6 Análisis de la imagen 31R\_M.tif

La figura 5.8 tiene un área  $A_z = 99.52\%$  y su mejor punto operacional tiene 0.9951 de sensibilidad y un 0.0058 de 1-especificidad. El siguiente punto tiene 0.9951 de sensibilidad y 0.0348 de 1-especificidad (tabla 5.7). Esta imagen tiene una baja cantidad de fallas, motivo por el cual se detectó la mayoría de ellas. La mejor combinación de parámetros ha generado 179 regiones, en cambio, la segunda combinación ha segmentado 1227 regiones. Al igual que los casos anteriores, el aumento en el tamaño de la mediana permite disminuir las regiones captadas.

*TABLA 5.7 Mejores puntos de la curva ROC de la imagen 31R\_M.tif*

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	6x6	30	9	Si	179	0.9951	0.0058	64.844
2	4x4	30	9	Si	1227	0.9951	0.0348	79.640



*FIGURA 5.8 Curva ROC de la imagen 31R\_M.tif*

### 5.1.7 Análisis de la imagen 39R\_M.tif

La figura 5.9 tiene un área  $A_z = 94.36\%$  y su mejor punto operacional tiene 0.8768 de sensibilidad y 0.0786 de 1-especificidad. El siguiente punto tiene 0.8518 de sensibilidad y 0.0586 de 1-especificidad (tabla 5.8). Esta imagen tiene una mayor cantidad de ruido; esto hace que la detección sea deficiente en determinar con mejor exactitud las regiones a segmentar. El primer punto se acerca más al óptimo, pero tiene una mayor cantidad de regiones con respecto al segundo punto; nuevamente la mediana influye en la disminución de las regiones.

TABLA 5.8 Mejores puntos de la curva ROC de la imagen 39R\_M.tif

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	3x3	24	27	Si	1110	0.8768	0.0786	83.453
2	5x5	30	27	Si	685	0.8518	0.0586	76.547

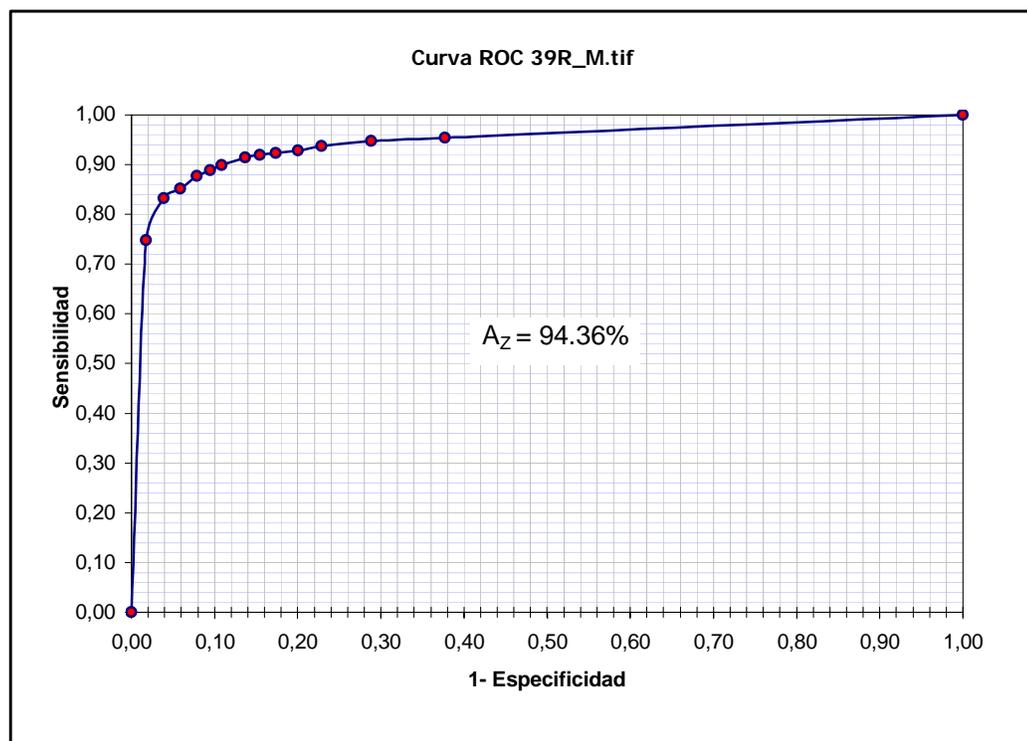


FIGURA 5.9 Curva ROC de la imagen 39R\_M.tif

### 5.1.8 Análisis de la imagen 40R\_M.tif

La figura 5.10 tiene un área  $A_z = 91.31\%$  y su mejor punto operacional tiene 0.8228 de sensibilidad y 0.0374 de 1-especificidad. El siguiente punto tiene 0.8229 de sensibilidad y 0.0453 de 1-especificidad (tabla 5.9). Debido a la gran cantidad de ruido en la imagen, el tamaño de la mediana ha sido significativo en la detección de una menor cantidad de regiones, pero a su vez, esto hace que disminuyan los valores de la sensibilidad y 1-especificidad. En este caso el factor preponderante ha sido el tamaño del área mínima; a medida que esta aumenta, el número de regiones segmentadas disminuye. Así en el primer punto, las estructuras con un área menor a 27 píxeles son eliminadas, quedando 731 regiones.

TABLA 5.9 Mejores puntos de la curva ROC de la imagen 40R\_M.tif

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	6x6	32	27	Si	731	0.8228	0.0374	91.843
2	6x6	30	9	Si	1270	0.8229	0.0453	81.516

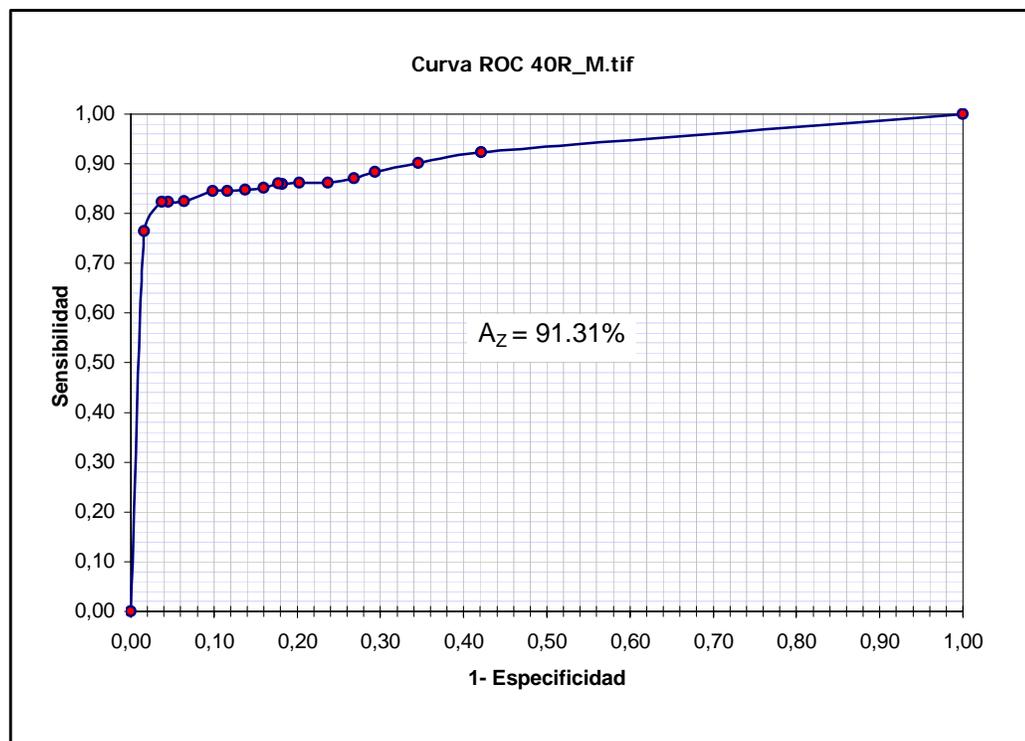


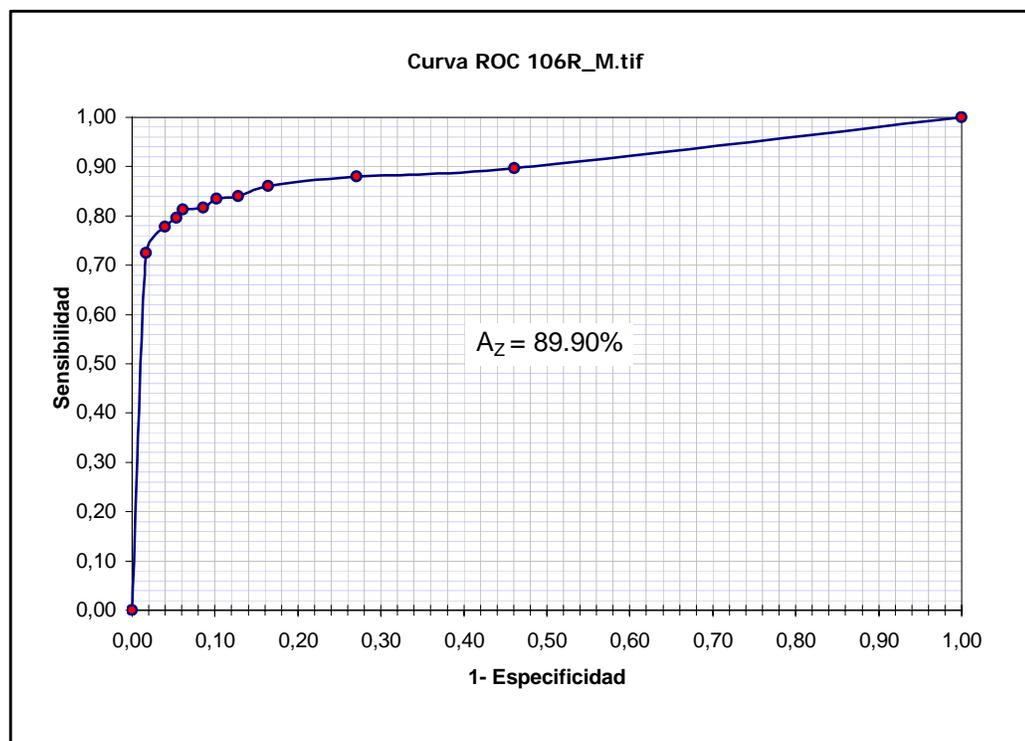
FIGURA 5.10 Curva ROC de la imagen 40R\_M.tif

### 5.1.9 Análisis de la imagen 106R\_M.tif

La figura 5.11 tiene un área  $A_z = 89.90\%$  y su mejor punto operacional tiene 0.8124 de sensibilidad y 0.0617 de 1-especificidad. El siguiente punto tiene 0.7954 de sensibilidad y 0.0539 de 1-especificidad (tabla 5.10). Los resultados indican la mayor dificultad para segmentar las fallas en este tipo de imágenes, y se debe a dos factores; el primero es el nivel de ruido en la imagen, y el segundo, la iluminación en la captura de la imagen radiológica. En este caso el aumento del área mínima ha determinado la cantidad de regiones segmentadas, así como la disminución en la sensibilidad y la 1-especificidad.

*TABLA 5.10 Mejores puntos de la curva ROC de la imagen 106R\_M.tif*

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	2x2	30	9	Si	836	0.8124	0.0617	51.766
2	2x2	30	18	Si	525	0.7954	0.0539	51.891



*FIGURA 5.11 Curva ROC de la imagen 106R\_M.tif*

### 5.1.10 Análisis de la imagen 107R\_M.tif

La figura 5.12 tiene un área  $A_z = 89.41\%$  y su mejor punto operacional tiene 0.8065 de sensibilidad y 0.1096 de 1-especificidad. El siguiente punto tiene 0.7926 de sensibilidad y 0.0951 de 1-especificidad (tabla 5.11). Esta imagen tiene una gran cantidad de ruido, y debido a ese motivo existe una gran cantidad de regiones segmentadas. Aun cuando el tamaño de la mediana aumente, los resultados indican una baja detección a medida que esta aumenta. Además existe un bajo nivel de contraste entre las fallas y su fondo. El aumento de la mediana en este caso disminuye notoriamente la sensibilidad y la 1-especificidad.

TABLA 5.11 Mejores puntos de la curva ROC de la imagen 107R\_M.tif

	Parámetros de entrada del algoritmo				Resultados de la curva ROC y tiempos de ejecución			
	Mediana	Disk Bottom	Área	Dilatador	Regiones	Sensibilidad	1-especificidad	Tiempo [s]
1	2x2	32	27	Si	2461	0.8065	0.1096	161.422
2	1x1	26	27	Si	2507	0.7926	0.0951	177.437

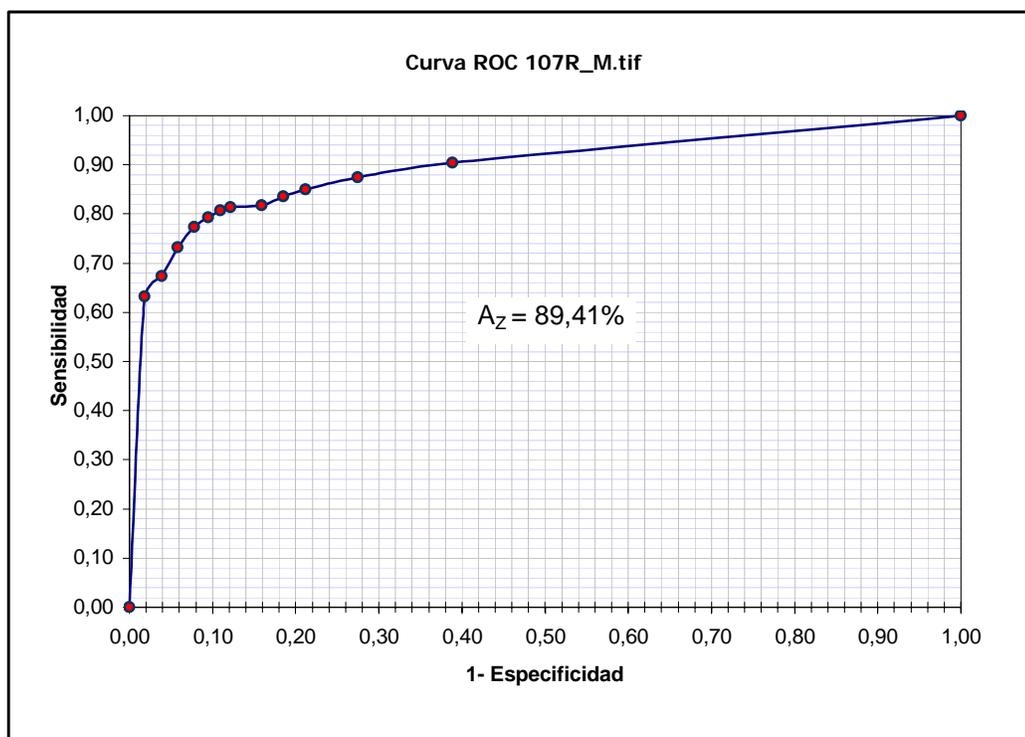


FIGURA 5.12 Curva ROC de la imagen 107R\_M.tif

### 5.1.11 Resultado general del estudio

Para que el estudio de las imágenes no dependa del conjunto analizado, se ha construido una curva ROC general. En ella se consideran las pruebas que utilicen los mismos valores, con el propósito de obtener un conjunto de parámetros globales que permita utilizar este filtro en otra imagen que no pertenezca al estudio. Para calcular la curva de la figura 5.13, se han sumado los valores  $TP$ ,  $FN$ ,  $FP$  y  $TN$  de cada prueba, teniendo en cuenta que el valor que se suma debe ser generado a partir de la misma prueba para cada imagen, luego se calculan los valores de sensibilidad y 1- especificidad según la ecuación 4.1 (pág. 81).

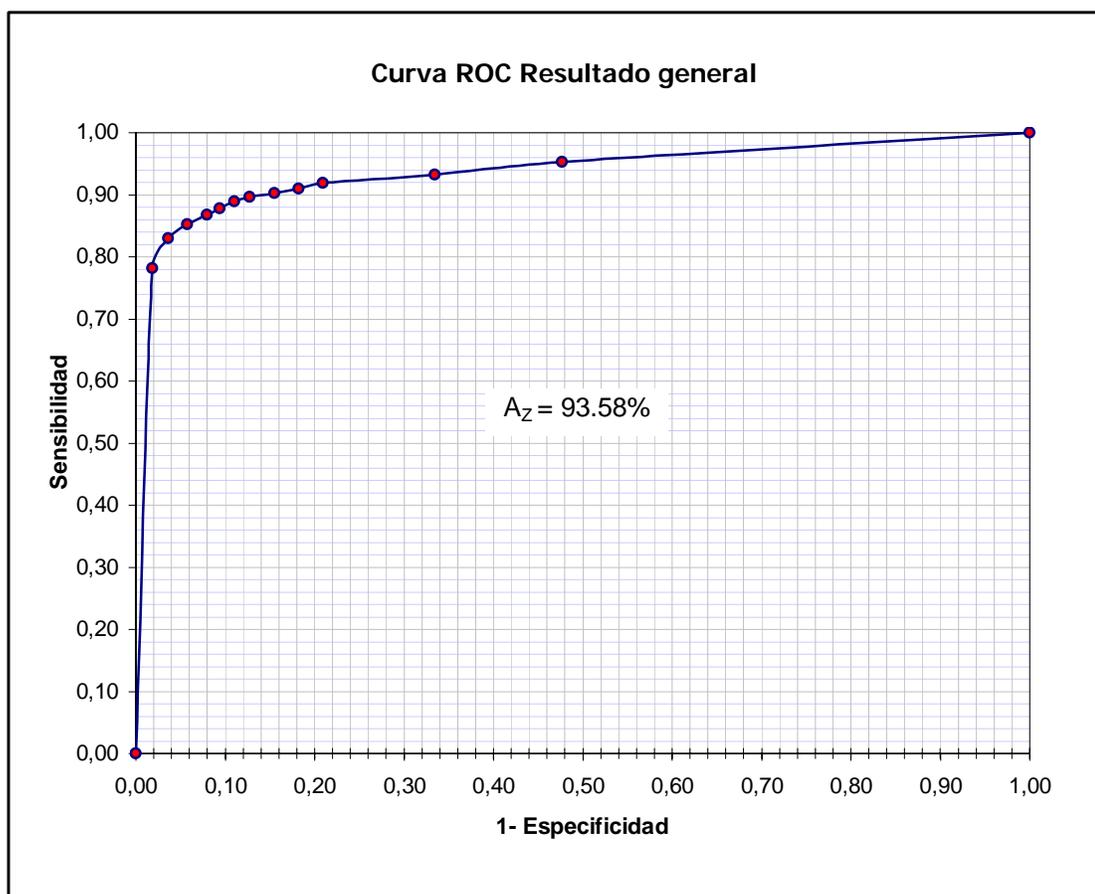


FIGURA 5.13 Curva ROC de los valores  $VP$ ,  $FN$ ,  $FP$ ,  $VN$  realizadas sobre el conjunto de pruebas con los mismos parámetros

La curva ROC de la figura 5.13 tiene un área  $A_z = 93.58\%$ , y su mejor punto tiene un 0.8783 de sensibilidad y 0.0940 de 1-especificidad. El siguiente punto tiene 0.8672 de sensibilidad y 0.0798 de 1-especificidad. En este último caso la disminución de las falsas alarmas se debe al aumento del área de detección; esto significa que todas las regiones menores a 27 píxeles no son consideradas como “fallas hipotéticas”.

En la tabla 5.12 se presentan las mejores 5 combinaciones que se aproximan al punto ideal (0,1) de la curva ROC. Se observa que la diferencia en la combinación de los parámetros es estrecha, siendo el tamaño de la mediana el que afecta en mayor grado el resultado del estudio; otros parámetros como el “área”, permiten aumentar la sensibilidad pero también afectan la 1-especificidad incrementándola. De igual forma la función del dilatador incrementa la sensibilidad y la 1-especificidad, debido a que aumenta el tamaño de la región segmentada una vez detectada. En el punto 4 de la tabla 5.12, el cambio del tamaño de la mediana de 4x4 respecto al punto 2 (con mediana de 3x3), produce una mayor disminución de las falsas alarmas, afectando en menor grado la detección de las fallas. Nuevamente se muestra que el tamaño de la mediana afecta el valor general de la segmentación, en especial el valor de las falsas alarmas, ya que un aumento de este valor, hace disminuir el valor de la 1-especificidad.

*TABLA 5.12 Resultados parámetros globales de la curva ROC general*

	Parámetros de entrada del algoritmo				Resultados de la curva ROC General	
	Mediana	Disk Bottom	Área	Dilatador	Sensibilidad	1-especificidad
1	3x3	30	9	Si	0.8783	0.0940
2	3x3	32	27	Si	0.8672	0.0798
3	2x2	30	18	Si	0.8891	0.1105
4	4x4	30	27	Si	0.8522	0.0573
5	2x2	30	9	Si	0.8966	0.1277

Para comprobar la calidad de la segmentación generada con el primer parámetro de la tabla 5.12, se emplea esta configuración en cada imagen analizada. La figura 5.14 representa la variación entre el valor óptimo de sensibilidad de cada curva ROC y la primera combinación de parámetros de la tabla 5.12. La figura 5.15 representa la misma relación anterior, excepto que, se analiza la variación de 1-especificidad.

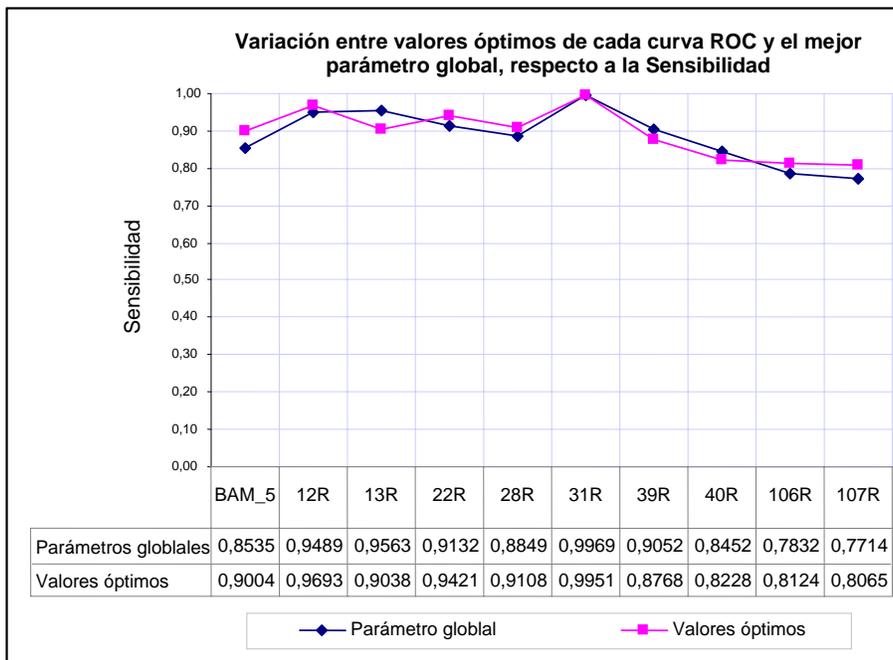


FIGURA 5.14 Variación entre los valores óptimos de sensibilidad de cada curva ROC y la primera combinación de parámetros de la tabla 5.12.

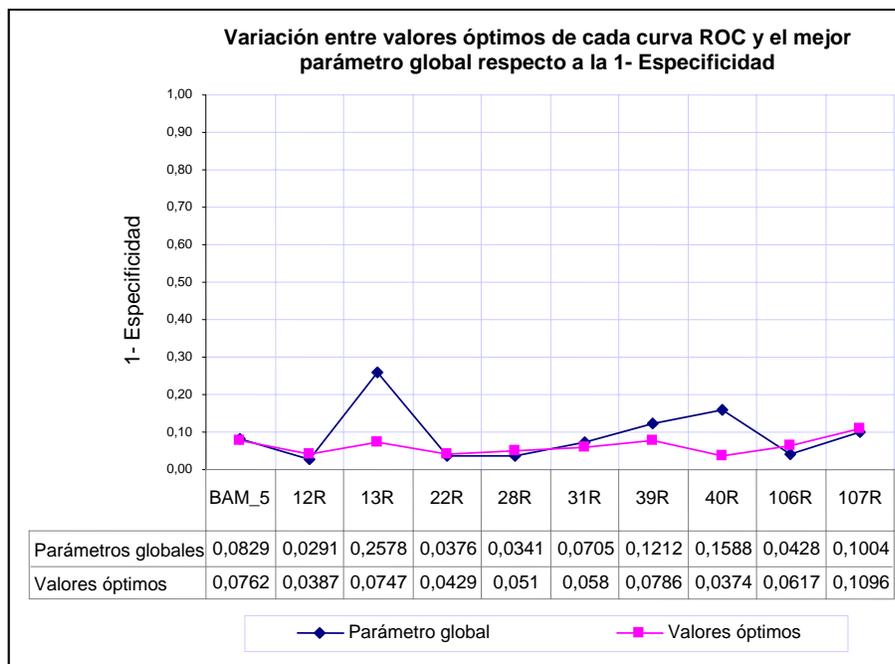
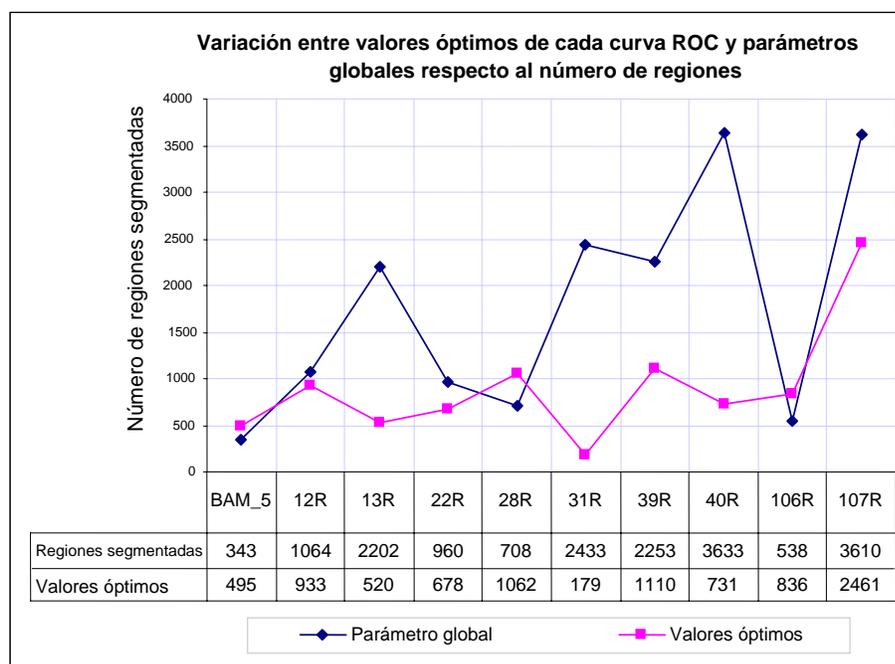


FIGURA 5.15 Variación entre los valores óptimos de 1-especificidad de cada curva ROC y la primera combinación de parámetros de la tabla 5.12.

En la figura 5.14, el valor óptimo de sensibilidad de cada curva ROC y el parámetro global propuesto no ha generado una mayor variación, siendo el error cuadrático medio de 0.1%. En algunos casos, el valor general es mejor que el óptimo, esto se refleja en las imágenes 13R, 39R y 40R, sin embargo, hay que recordar que el óptimo de la curva ROC es el valor que se aproxime más a la coordenada (0,1), no siendo necesariamente el mayor valor en sensibilidad. En la figura 5.15, la curva de 1-especificidad ha generado una mayor variación entre el mejor valor de cada imagen y el parámetro global, con un error cuadrático medio de 0.5%. En el caso de las imágenes 13R, 39R y 40R, los valores de 1-especificidad superan en gran cuantía el valor óptimo, es decir, existe un mayor porcentaje de falsas alarmas.

La figura 5.16 presenta una diferencia marcada entre las regiones segmentadas a través de los parámetros óptimos de cada imagen y el parámetro global. Esto se debe a que existe una gran cantidad de regiones de tamaño reducido que no altera en mayor proporción el porcentaje de falsas alarmas, pero si aumenta el número de regiones segmentadas.



*FIGURA 5.16 Variación entre el número de regiones segmentadas de cada curva ROC y la primera combinación de parámetros de la tabla 5.12.*

Para solucionar el problema del alto número de regiones segmentadas (siendo su mayoría regiones con ruido), se puede utilizar un procesamiento que analice las características de las fallas, también conocido como extracción de características y luego un clasificador.

En general, los parámetros globales determinados a través de la curva ROC (figura 5.13), han permitido establecer una combinación que se acerca a los valores óptimos de cada curva ROC, de todas las imágenes estudiadas. El objetivo consiste en utilizar estos parámetros en nuevas imágenes que no se encuentren en el estudio.

### 5.1.12 Comparación de imagen ideal

El filtro propuesto se ha contrapuesto con el método desarrollado en (Mery & Berti, 2003). Para realizar la comparación se ha generado una imagen binaria en forma manual la cual contiene la totalidad de las fallas reales de la imagen original. Una vez que se ha determinado las regiones segmentadas a través del filtro propuesto y el filtro de análisis de texturas, se procede a comparar en forma individual con la imagen binaria ideal.

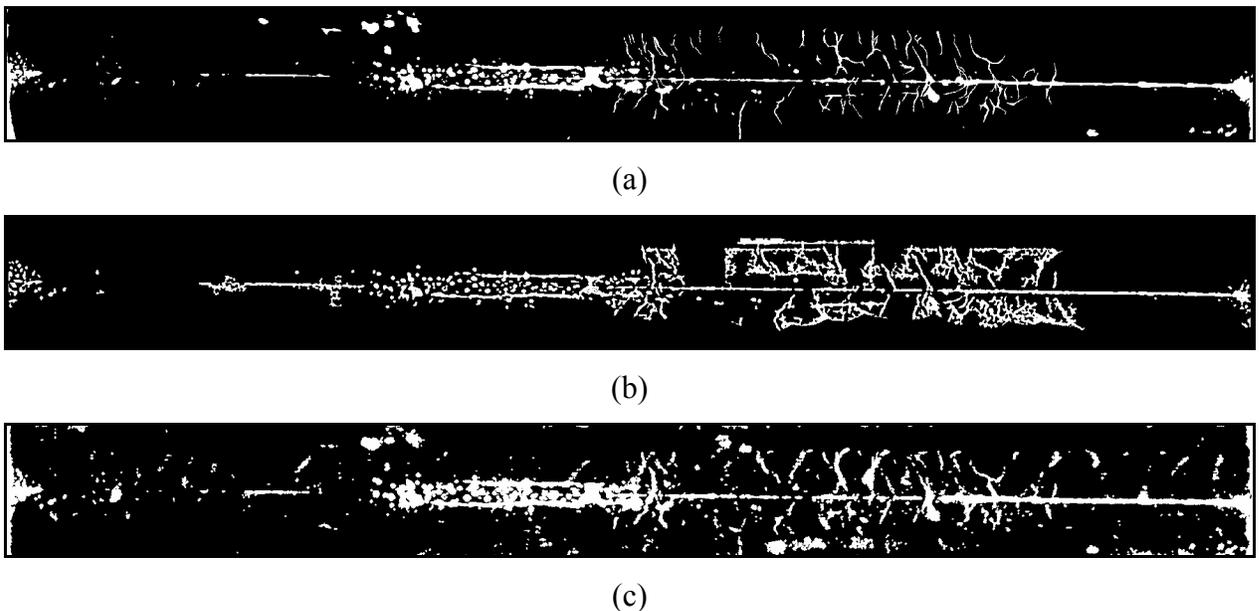
Según la tabla 5.13, los resultados indican que la sensibilidad del filtro propuesto tiene 90.04% respecto a 64.63% del método de análisis de texturas, y la 1-especificidad tiene 7.62% comparada con 4.86%. Esto significa que el método propuesto detecta una mayor cantidad de falsas alarmas, pero a su vez detecta una mayor cantidad de fallas reales.

*TABLA 5.13 Comparación entre el filtro desarrollado y el método de análisis de texturas de la imagen BAM-5*

IMAGEN	PROCESO	REGIONES SEGMENTADAS	REGIONES CON CLASIFICADOR	SENSIBILIDAD	1- ESPECIFICIDAD
Bam5.tif	Segmentación bottom-hat (Filtro propuesto)	495	--	90.04%	7.62%
Bam5.tif	Análisis de Texturas (Mery & Berti, 2003)	1419	187	64.13%	4.86%

En cuanto a las regiones segmentadas, el método de análisis de texturas triplica en número a las regiones encontradas por el filtro propuesto, pero al utilizar el proceso de extracción de características y clasificación, el número de regiones disminuye a 187.

La figura 5.17 presenta la comparación entre los dos tipos de procesos de segmentación realizados. Una vez construida la imagen ideal (figura 5.17a), es posible realizar la comparación entre la figura 5.17b con la imagen ideal y también la figura 5.17c con la imagen ideal. Los resultados de esta comparación se presentan en la tabla 5.13.



*FIGURA 5.17 (a) Imagen binaria ideal de BAM-5, (b) Imagen binaria realizada a través del análisis de texturas (Mery & Berti, 2003), (c) Imagen binaria realizada a través del proceso de segmentación propuesto.*

Estos resultados indican que el filtro propuesto presenta dos ventajas; la primera es tener una menor cantidad de regiones; esto significa que al insertar un posterior proceso de extracción de características y un clasificador se analizará una menor cantidad de regiones, lo cual está relacionado en una menor cantidad de tiempo de procesamiento. La segunda ventaja consiste en un mayor porcentaje de regiones con fallas reales y bajo porcentaje de falsas alarmas; de este modo, al aplicar el proceso de segmentación se están considerando la mayoría de las fallas reales.

# **CAPÍTULO 6 DISCUSIÓN DE LOS RESULTADOS.**

## **6.1 DISCUSIÓN DE LOS FILTROS**

El proceso de segmentación propuesto es el resultado de la aplicación de distintas técnicas que en conjunto permiten separar las regiones factibles de ser fallas del resto de la imagen. De acuerdo a los objetivos planteados, el estudio ha permitido seleccionar los métodos que se adapten mejor al desarrollo de la solución, teniendo en cuenta que el problema se encuentra inserto en el área de las fallas de soldaduras. Por este motivo, se procede a discutir y analizar las ventajas y desventajas de la aplicación de cada procedimiento utilizado.

En la etapa de reducción del ruido se ha utilizado el filtro de la mediana, debido a que es un indicador más robusto que el promedio y que el filtro Gaussiano, ya que un píxel no representativo no introduce su valor en el resultado. Además la mediana no crea nuevos valores de los píxeles cuando trabaja en los bordes. Es por esta razón que el filtro de la mediana es mucho mejor para preservar los bordes claramente que el filtro promedio y el filtro Gaussiano.

A continuación se utiliza el filtro bottom-hat ya que permite separar la falla del fondo, siendo considerado en este estudio como el principal segmentador del algoritmo. Las siguientes estrategias giran en torno al resultado generado por este filtro, a través de dos líneas: el filtro de Canny y la umbralización binaria. El método de Canny tiene la ventaja de ser sensible al ruido y detecta con mayor precisión los bordes de las estructuras, sin embargo, una gran cantidad de bordes se encuentran abiertos, razón por la cual es necesario realizar el proceso de dilatación, llenado y erosión. La desventaja se encuentra precisamente en la generación de bordes abiertos. En cambio, la ventaja de la umbralización binaria consiste en generar la mayoría de las regiones con fallas ya cerradas, ya que sólo se requiere de un proceso de eliminación del ruido, que se puede aplicar eficientemente con los operadores morfológicos.

Una vez que se ha determinado utilizar la umbralización, se procede a estudiar dos variantes que determinan la segmentación a través de la transformada de Watershed. La primera la constituye la aplicación de la transformada de la distancia a las regiones binarias, de manera de simular las tonalidades de los niveles de gris de las fallas y, la segunda consiste en copiar sólo las regiones binarias como fallas de la imagen original.

La transformada de la distancia no representa los niveles de gris de las fallas de la imagen original. Debido a esto, al aplicar la transformada de Watershed se genera una segmentación imprecisa, en cambio el segundo método denominado “Corte de secciones”, ha permitido generar una segmentación con mayor precisión, ya que se utilizan los mismos píxeles de la imagen original. El resultado experimental muestra que en el segundo caso la división fue más precisa, ya que se obtienen divisiones de acuerdo a la imagen real y no a una imagen simulada como es la generada por la transformada de la distancia.

Al aplicar la transformada de Watershed sobre las fallas hipotéticas, se segmentan sólo dichas regiones y no las adyacentes, las cuales han sido descartadas en el proceso bottom-hat. Además, al aplicar la modificación de los mínimos, se puede regular la cantidad de regiones a segmentar al determinar la cantidad de píxeles que componen la mínima. Efectivamente, a medida que el valor de los mínimos crece, la cantidad de regiones segmentadas a través de Watershed disminuye.

## **6.2 DISCUSIÓN DE LOS RESULTADOS EXPERIMENTALES**

Uno de los principales filtros utilizados para detectar las fallas hipotéticas es el filtro bottom-hat. En el caso que la falla tenga un mínimo de contraste con su fondo, este filtro no la detectará. El ruido tiene un papel preponderante en el resultado de la segmentación, ya que si este es elevado, se debe aplicar una máscara de mayor tamaño, con lo cual las fallas de baja intensidad desaparecerán. En cambio, si se aplica una máscara de menor tamaño, se genera una gran cantidad de regiones que en su mayoría corresponde a regiones con ruido.

Los análisis de los resultados indican que el filtro es sensible al ruido; a medida que este aumenta se detecta una mayor cantidad de regiones, por el contrario, un menor nivel de ruido genera una menor cantidad de regiones segmentadas. Este efecto se minimiza utilizando el filtro de la mediana, debido a sus propiedades de atenuación del ruido y preservación de los bordes de las estructuras.

El filtro LoG (Mery & Filbert, 2002) tiene una desventaja comparativa con respecto al filtro de bottom-hat, específicamente en la imagen BAM-5. La cantidad de “fallas hipotéticas” triplica en número al filtro bottom-hat. Esto se debe a que el filtro LoG detecta los cambios en las intensidades de gris y, en consecuencia, se genera un conjunto de bordes que identifica cada variación. Posteriormente se utilizan los bordes que se encuentren cerrados, debido a que las regiones cerradas contienen las “fallas hipotéticas”. En cambio el filtro bottom-hat, genera un conjunto de regiones que es la diferencia entre una imagen libre de fallas y la imagen original, preservando las regiones factibles de fallas. El posterior proceso consiste en aplicar una umbralización binaria y de esta manera generar regiones cerradas.

Este trabajo se ha comparado con el método desarrollado en (Mery & Berti, 2003). Este último tiene la característica de realizar el proceso de segmentación a través del filtro LoG, luego el proceso de extracción de características a través de la matriz de co-ocurrencia y la función Gabor y posteriormente el proceso de clasificación a través del método polinomial, Mahalanobis y vecinos cercanos. Claramente la comparación del filtro propuesto no es justa ya que se ha realizado sólo el proceso de segmentación, no obstante, los resultados pueden mejorar si se aplica las siguientes etapas de la AVI, como la extracción de características y un clasificador. Los resultados indican que la ‘Sensibilidad’ del método propuesto en comparación con el método de análisis de texturas tiene 90.94% y 64.13% respectivamente. Por otra parte, la ‘1-especificidad’ del método propuesto en comparación con el método de análisis de texturas tiene 7.62%, y 4,86% respectivamente.

Los resultados de la sección 5.1.11, indican que el mejor punto operacional del algoritmo se presenta en la primera combinación de parámetros de la tabla 5.12. Los resultados indican una sensibilidad de 87.83% y 9.40% de 1-especificidad con un área de 93.58%. Se aprecia que en los

cinco mejores resultados, el tamaño del disco del filtro bottom-hat se ha mantenido entre 30 y 32 píxeles, en cambio uno de los parámetros que ha afectado el resultado de la segmentación, ha sido el tamaño de la mediana. A medida que aumenta su tamaño, disminuye el ruido y del mismo modo las falsas alarmas; el efecto negativo es que produce una disminución en la detección de fallas reales.

Otro parámetro que afecta el resultado es la elección del tamaño del área. Para el estudio se establecieron 3 tamaños: de 9, 18 y 27 píxeles. A medida que el tamaño aumenta, se eliminan las regiones con el área seleccionada y disminuyen las falsas alarmas, ya que en su mayoría es ruido que ha permanecido luego del proceso de la matemática morfológica.

Con respecto al tiempo de ejecución, depende de distintos factores, pero hay dos preponderantes: el primero tiene relación con el tamaño de la imagen. Si se incrementa el número de píxeles, también aumenta el tiempo de ejecución por cada píxel analizado. El segundo factor tiene relación con la cantidad de regiones segmentadas; por ejemplo en la figura 5.12 el mejor punto operacional de la curva ROC tiene 2461 regiones y un tiempo de ejecución de 161.422s (tabla 5.11); esto afecta el rendimiento del algoritmo dada la gran cantidad de regiones que se deben analizar. Comparada con la imagen BAM-5 (figura 5.3), los tiempos han sido inferiores, de 30.484s para el primer caso y 32.563s en el segundo (tabla 5.2). Sin embargo, esta imagen tiene una menor cantidad de ruido y su tamaño es inferior al resto de las imágenes del estudio.

La relación entre las variables área  $A_z$  y la velocidad de procesamiento ( $Megapíxel \times seg$ ) se presenta en la figura 5.1. En ella se interpreta la influencia que tiene el nivel de ruido en la imagen. El gráfico refleja la relación indirecta entre el ruido y la velocidad de procesamiento, es decir, a medida que el ruido de la imagen aumenta, disminuye la velocidad de procesamiento. También indica que el área  $A_z$  aumenta en relación con la velocidad de procesamiento, este resultado muestra que el ruido tiene una clara influencia entre el tiempo que toma procesar la imagen y la cantidad de falsas alarmas detectadas.

## CAPÍTULO 7 REFERENCIAS

- (Beucher et al, 1979) BEUCHER, S.; LANTUÉJOUL, C. (1979): “*Use of Watersheds in Contour Detection*”. Proc. Int. Workshop on image processing. Rennes, France, September, pp. 17-21.
- (Beucher, 1991) BEUCHER, S. (1991): “*The Watershed Transformation applied to Image Segmentation*”. 10th Pfefferkorn Conf. on Signal and Image Processing in Microscopy and Microanalysis, 16-19 September.
- (Bresler et al, 1973) BRESLER, B.; LIN, T.; SCALZI, J. (1973): “*Diseño de estructuras de acero*”. Limusa-Wiley. México, pp. 215-230.
- (Breu et al, 1995) BREU, H.; GIL, J.; KIRKPATRICK, D.; WERMAN, M. (1995): “*Linear Time Euclidean Distance Transform Algorithms*”. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 17, no. 5, May, pp. 529-533.
- (Canny, 1986) CANNY, J. (1986): “*A Computational Approach to Edge Detection*”. IEEE Trans. Pattern Analysis and Machine Intelligence, PAMI-8:(6), pp. 679-698.
- (Castleman, 1996) CASTLEMAN, K.R. (1996): “*Digital Image Processing*”. Prentice-Hall, New Jersey.
- (Eddins, 2004) EDDINS, S. (2002): “*The Watershed Transform, Strategies for Image Segmentation*”. URL: [http://www.mathworks.com/company/newsletters/news\\_notes/win02/watershed.html](http://www.mathworks.com/company/newsletters/news_notes/win02/watershed.html). Acceso: 18/05/2004.
- (Egan, 1975) EGAN, J. (1975): “*Signal detection theory and ROC analysis*”. Academic Press, New York.
- (Escalera, 2001) DE LA ESCALERA, H.A. (2001): “*Visión por Computador, fundamentos y métodos*”. Prentice Hall. Madrid, España.
- (Gayer et al, 1990) GAYER, A.; SAYA, A.; SHILOH, A. (1990): “*Automatic recognition of welding defects in real-time radiography*”. NDT International, 23(4):131–136.
- (González, 1992) GONZÁLEZ R.; WOODS, R.E. (1992): “*Digital Image Processing*”. Addison Wesley, U.S.A.

- (Heath, 1996) HEATH, M.D. (1996): “*A Robust Visual Method For Assessing The Relative Performance Of Edge Detection Algorithms*”. Thesis of Master of Science in Computer Science, Department of Computer Science and Engineering, College of Engineering, University of South Florida, December.
- (Lawson & Parker, 1994) LAWSON, S.; W, PARKER G.A. (1994): “*Intelligent segmentation of industrial radiographic images using neural networks*”. Machine Vision Applications and Systems Integration III, Proc. of SPIE, volume 2347, November, pp. 245–255.
- (Li, 2004) LI, Y. (2004): “*Edge Detecction*”. URL: <http://www.cs.washington.edu/research/imagedatabase/demo/edge/>. University of Washington, Department of Computer Science & Engineering. Acceso: 18/05/ 2004.
- (Li & Liao, 1996) LIAO, T.W.; LI, Y.M. (1996): “*Weld defect detection based on Gaussian Curve*”. Proceedings of the 28th Southeastern Symposium on System Theory (SSST '96).
- (Liao & Li, 1998) LIAO, T. W.; LI, Y. M. (1998): “*An Automated Radiographic NDT System for Weld Inspection*”. Part II – Flaw detection. NDT&E International, 31(3):183-192.
- (Liao, 2003) LIAO, T.W. (2003): “*Classification of welding flaw types with fuzzy expert systems*”. Expert Systems with Applications, pp. 101–111.
- (Mathworks, 2003) MATHWORKS (2003); “*Image Processing Toolbox for Use with MATLAB: Users Guide*”. The MathWorks Inc, January.
- (Medina & Mery, 2003) MEDINA, O.; MERY, D. (2003): “*Inspección visual automática de botellas de vino usando métodos de mediana adaptada*”. En Actas del Encuentro Chileno de Ciencias de la Computación, 3-8 Noviembre, Chillán.
- (Meijster et al, 1995) MEIJSTER, A.; ROERDINK, J.B.T.M. (1995): “*The implementation of a parallel Watershed algorithm*”. Proc. Computing Science in the Netherlands, Utrecht, Netherlands, November, pp. 134-142.
- (Meijster et al, 1998) MEIJSTER, A.; ROERDINK, J.B.T.M. (1998): “*A Disjoint set Algorithm for the Watershed Transform*”. Signal Processing IX Eusipco, vol III, pp.1665-1668.

- (Mery, 2002) MERY, D. (2002): “*Inspección Visual Automática*”. Primer Congreso Internacional de Ingeniería Mecatrónica. Lima, Perú, 8-12 Abril.
- (Mery et al, 2003) MERY, D.; DA SILVA, R.; CALÔBA, L.; REBELLO, J. (2003): “*Pattern Recognition in the Automatic Inspection of Aluminium Castings*”. *Insight*, 45(7):475-483, ISSN 1354-2575.
- (Mery & Filbert, 2002) MERY, D.; FILBERT D. (2002): “*Automated Flaw Detection in Aluminum Castings Based on the Tracking of Potential Defects in a Radioscopic Image Sequence*”. *IEEE Transactions on Robotics and Automation*, 18(6): 890-901, ISSN 1042-296X.
- (Mery & Berti, 2003) MERY, D.; BERTI, .M.A. (2003): “*Automatic Detection of Welding Defects using Texture Features*”. *Insight*, 45(10):676-681, ISSN 1354-2575.
- (Mery & Pedreschi, 2004) MERY, D.; PESDRESCHI F. (2004): “*Segmentation of colour food images using a robust algorithm*”. *Journal of Food Engineering*, March.
- (Meyer et al, 2002) MEYER, F.; VACHIER, C. (2002): “*Image Segmentation Based on Viscous Flooding Simulation*”. *Proc. of the Vith International Symposium of Mathematical Morphology*, Hugues Talbot and Richard Bear Ed., CSIRO publishing, April, pp. 69-77.
- (Newman & Jain, 1995) NEWMAN, T.S.; JAIN, A.K.(1995): “*A survey of automated visual inspection*”. *Computer Vision and Image Understanding*, 61(2):231-262.
- (Pichel, 2002) PICHEL, J.C. (2002): “*Algoritmo paralelo de segmentación basado en agrupamiento de regiones en imágenes sobresegmentadas*”. Memoria de Licenciatura, Universidad de Santiago de Compostela, Departamento de Electrónica e Computación. España.
- (Roerdink et al, 2001) ROERDINK, J.B.T.M.; MEIJSTER, A. (2001): “*The Watershed Transform: Denitions, Algorithms and Parallelization Strategies*”. *Fundamenta Informaticae*, N° 41, pp. 187-228.

- (Sang et al, 1998) SANG, P.H.; BEOM, R.J. (1998): “*Homogeneous Region Merging Approach for Image Segmentation Preserving Semantic Object Contours*”. International Workshop on Very Low Bitrate Video Coding, Urbana, IL, USA. October.
- (Silva et al, 2002) SILVA, R.R.; SIQUEIRA, M.H.S.; CALÔBA, L.P.; DA SILVA, I.C.; DE CARVALHO, A.A.; REBELLO, J.M.A. (2002): “*Contribution to the development of a radiographic inspection automated system*”. Proceedings of the 8th European Conference on Non-Destructive Testing (ECNDT 2002), Barcelona, 17-21 June.
- (Soille et al, 1990) SOILLE, P., VINCENT, L. (1990): “*Determining Watershed in Digital Pictures via Flooding Simulation*”. Proc. SPIE Vol 1360, Visual communications and image processing. Lausavre, Switzerland. October, pp. 240-250
- (Sofia & Redouane, 2002) SOFIA, M.; REDOUANE, D. (2002): “*Shapes recognition system applied to the non destructive testing*”. Proceedings of the 8th European Conference on Non-Destructive Testing (ECNDT 2002), Barcelona. 17-21 June.
- (Somerville, 2000) SOMERVILLE, I. (2000): “*Software Engineering*”. 6<sup>th</sup> Edition, Addison Wesley Pub Co.
- (Vincent et al, 1991) VINCENT, L.; SOILLE, P. (1991): “*Watersheds in Digital Space: And Efficient Algorithm Based on Immersion Simulations*”. IEEE Transactions on PAMI, 13(No. 6), 583-598.
- (Vincent, 1993) VINCENT, L. (1993): “*Morphological Grayscale Reconstruction in Image Analysis: Applications and Efficient Algorithms*”. IEEE Transactions on Image Processing, Vol. 2, No. 2, April, pp. 176-201.
- (Wang & Liao, 2002) Wang, G.; Liao, W. (2002): “*Automatic Identification of different types of welding defects in radiographic images*”. NDT&E International, 35:519-528.

## APÉNDICE A CÓDIGO FUENTE

### 7.1 CÓDIGO DE SEGMENTACIÓN DE WATER\_5.M

```

%Funcion de Segmentacion de bordes
%Autor: Miguel Carrasco Z.
Close All;
set(0, 'DefaultFigureColor', 'w')

%---- Parametros de Entrada ----%
Mediana= [3 3];
DiskBottom=26;
Area=27;
Strel_1 = strel('square',1);
Strel_2 = strel('disk',2);
Strel_3 = strel('disk',3);
se = strel('disk', DiskBottom);
I = imread('bam5.tif');% Ingreso de la imagen a segmentar

%---- Preprocesamiento y Procesamiento Morfologico
figure, imshow(I), title('Imagen Original'); axis on
J = medfilt2(I,Mediana); figure, imshow(J), title('Imagen Original con mediana');axis on
Ibot = imbothat(J, se); figure, imshow(Ibot, []), title('Filtro bottom-hat');axis on
Ibot = imadjust(Ibot, [0.015 0.30], [0 1],1);
Ibot = immultiply(Ibot,Ibot);
Ibot = roicolor(Ibot, 6, 256);figure, imshow(Ibot, []), title('Roicolor'); axis on
Ibot = imerode (Ibot,Strel_2);
Ibot = imdilate(Ibot,Strel_2);figure, imshow(Ibot, []), title('Limpieza binaria '); axis on

%---- Eliminacion de regiones por tamaño de las estructuras
BW=Ibot;
[L,REGIONES]=bwlabel(BW,4);
RGB = label2rgb(L);
stats = imfeature(L,'all');
idx = find([stats.Area]>Area);
BW2 = ismember(L,idx); figure, imshow(BW2);title('Corte por area');

Ibot=BW2;
[L,REGIONES]=bwlabel(Ibot,4);REGIONES
%Funcion de dilatacion borrar comentario si se activa
%Ibot = imdilate(Ibot,Strel_3);

%--- Procesamiento de Seccion de corte e imposicion de minimos de Watershed
ii = find(Ibot==0);
Z = J;
Z(ii)=255*ones(size(ii,1),1); figure, imshow(Z,[]); title('Imagen Recortada');axis on
TDZ= im2uint8(Z);
Iemin = imextendedmin(Z,4); %4 u 8
Iimpose = imimposemin(TDZ, Iemin); figure, imshow(Iemin), title('Imposicion la Minima'); axis on
figure, imshow(Iimpose), title('Imagen recortada con imposicion la Minima'); axis on

%--- Aplicacion Watershed a la imagen con preprocesamiento de marcadores
wat = watershed(Iimpose); figure, imshow(label2rgb(wat,'jet','w')),title('Separacion de Watershed'); axis on
Sep= imcomplement(im2uint8(wat)); figure, imshow(Sep,[]), title('Separacion de las lineas de Watershed');
axis on
Salida= imadd(im2uint8(~Ibot), im2uint8(Sep)); figure, imshow(Salida,[]),title('Salida binaria'); axis on

%--- Marca de los bordes sobre la imagen original
BWoutline = bwperim(Salida);
Segout = I;
Segout(BWoutline)=0; figure, imshow(Segout,[]),title('Segmentacion final de Watershed'); axis on

```

## 7.2 CÓDIGO DE COMPARACIÓN DE PÍXELES COMPARA.M

```

% Codigo de comparacion pixel a pixel con la imagen ideal

close all;
BIN = imread('Bam5_bin.tif');
Ibot= imread('Bam5_Berti_Clas.tif');

f_positivos=0;
f_negativos=0;
v_positivos=0;
v_negativos=0;
error=0;
[alto, largo]=size(BIN);
for i=1:alto
    for j=1:largo
        if Ibot(i,j)==1 & BIN(i,j)==1 %si hay falla en ese pixel
            v_positivos=v_positivos+1;
        elseif Ibot(i,j)==1 & BIN(i,j)==0 %
            f_positivos=f_positivos+1;
        elseif Ibot(i,j)==0 & BIN(i,j)==1 %
            f_negativos=f_negativos+1;
        elseif Ibot(i,j)==0 & BIN(i,j)==0 %s
            v_negativos=v_negativos+1;
        else
            error=error+1;
        end
    end
end

SN= v_positivos/(v_positivos+f_negativos)
SP= f_positivos/(f_positivos+v_negativos)

```

## 7.3 CÓDIGO DE SELECCIÓN DE PUNTOS DE LA CURVA ROC

```

%Seleccion de los mejores puntos de la curva ROC

close all;
A=xlsread('columna_GRAL.xls');
n=0;
r=0;
B= [zeros(60,2)]
for j=1:-0.02:0.02
    r=r+1;
    for i=1:65
        n=n+1;
        if A(i,2)<j & A(i,2)>(j-0.02)
            if B(r,1)<A(i,1)
                B(r,2)=A(i,2)
                B(r,1)=A(i,1)
            end
        end
    end
end
end
end

```

## APÉNDICE B IMÁGENES IDEALES Y SEGMENTADAS

## 7.4 COMPARACIÓN DE BAM5.TIF

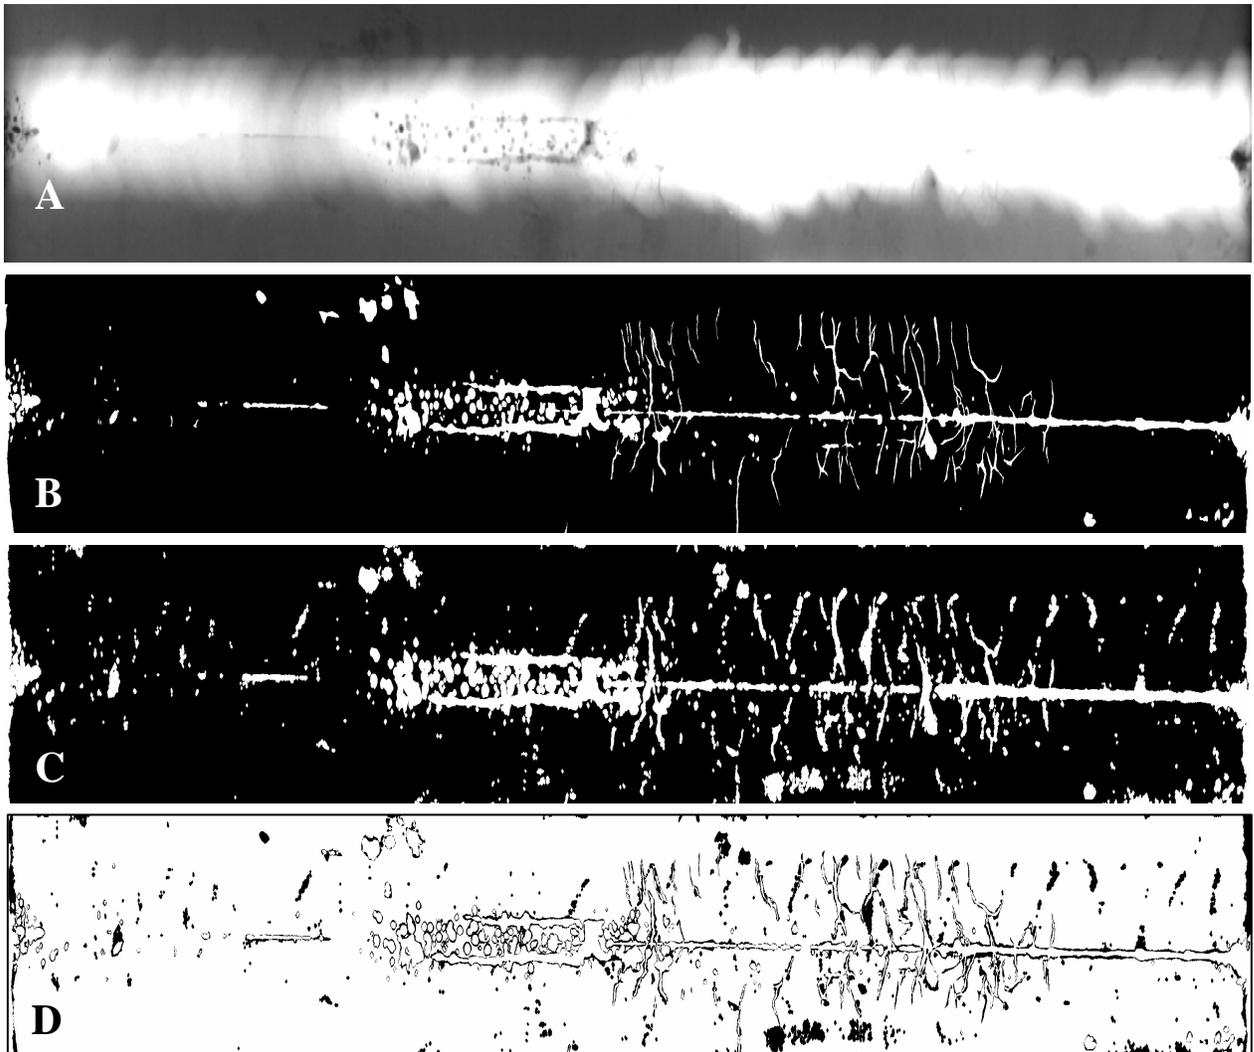


FIGURA 7.1 (a) Imagen original BAM-5, (b) Imagen binaria ideal fallas de BAM-5,  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 7.62%

## 7.5 COMPARACIÓN DE 12R\_M.TIF

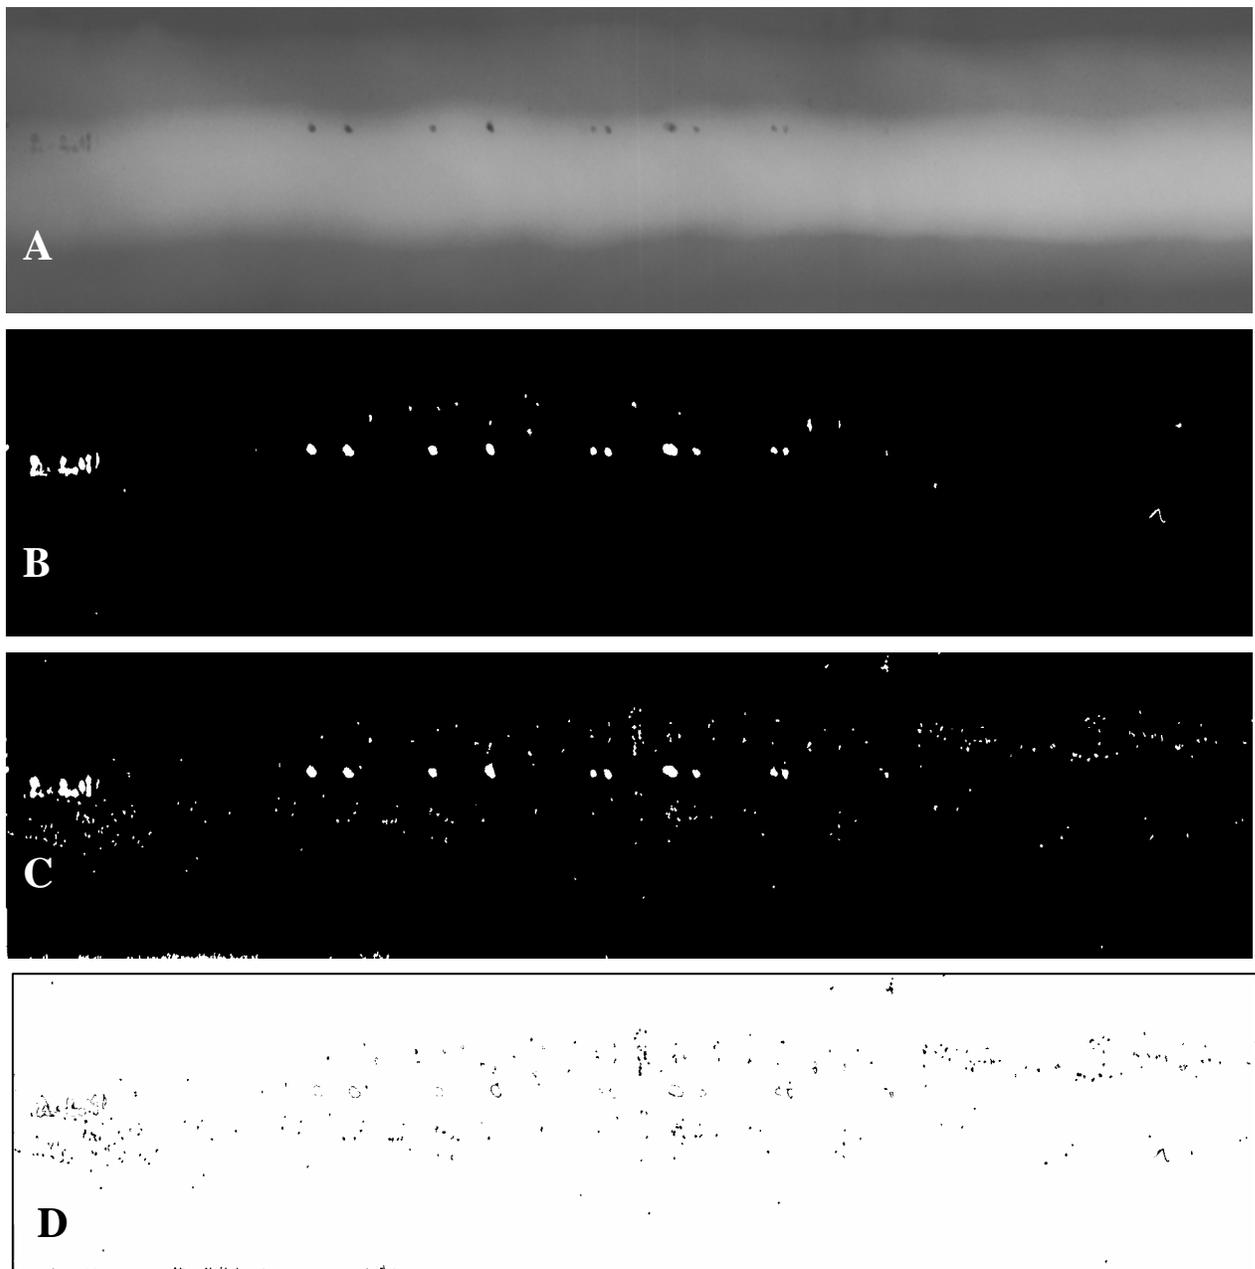


FIGURA 7.2 (a) Imagen original 12R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 3.87%

## 7.6 COMPARACIÓN DE 13R\_M.TIF

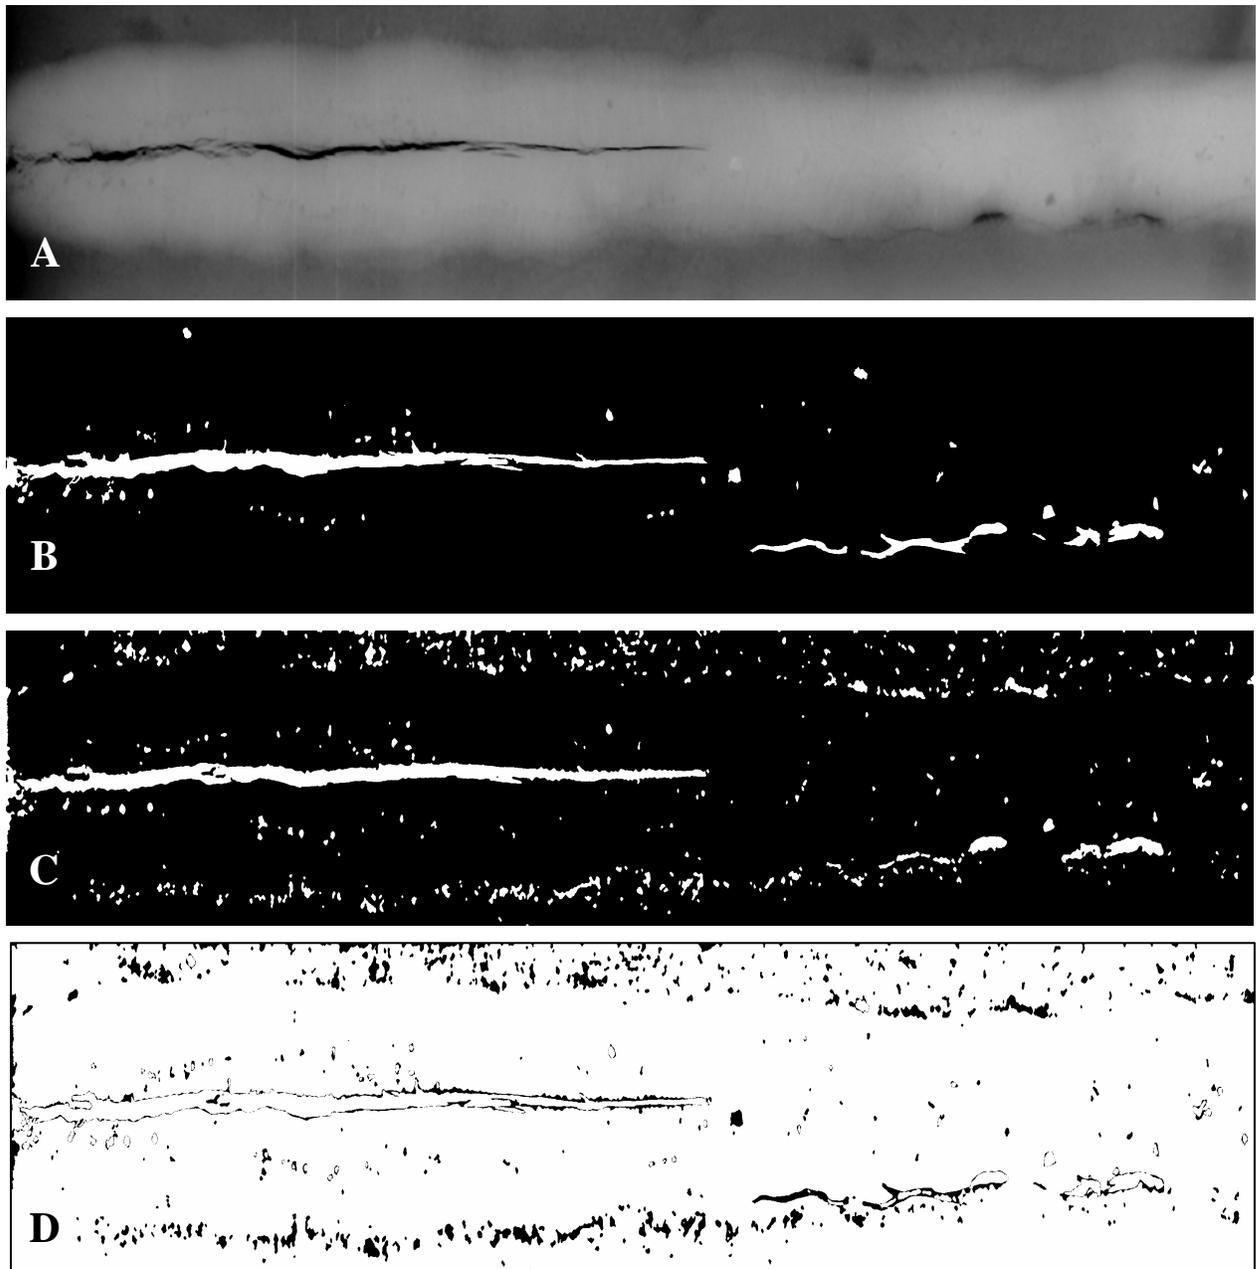


FIGURA 7.3 (a) Imagen original 13R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 7.47%

## 7.7 COMPARACIÓN DE 22R\_M.TIF

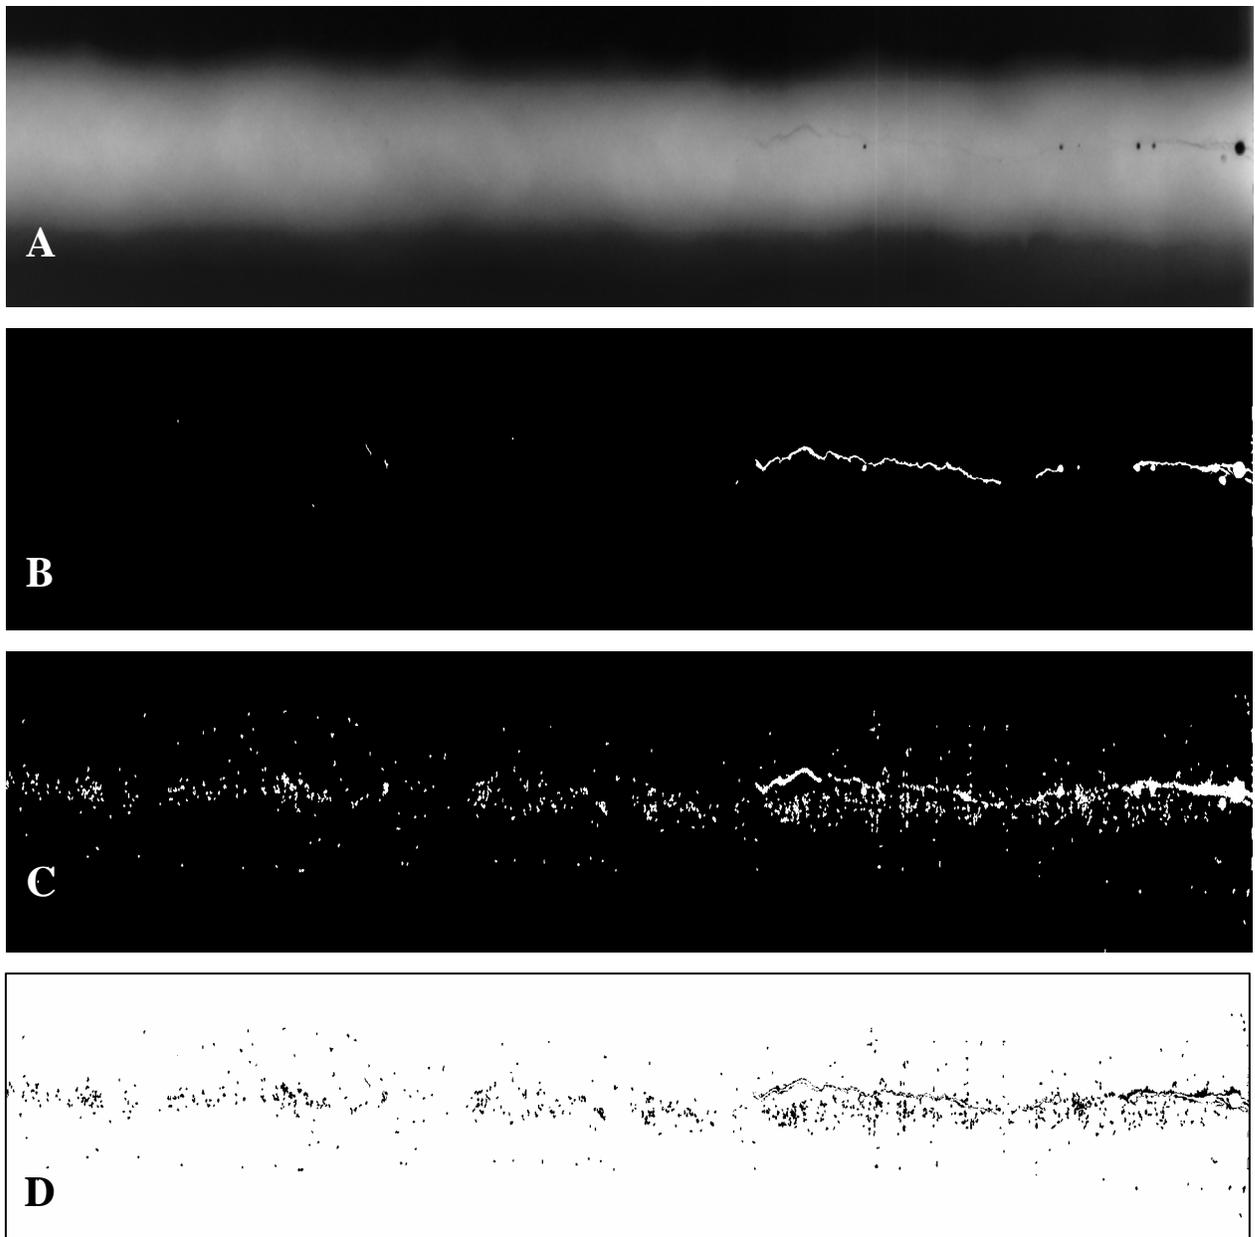


FIGURA 7.4 (a) Imagen original 22R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 4.29%

## 7.8 COMPARACIÓN DE 28R\_M.TIF

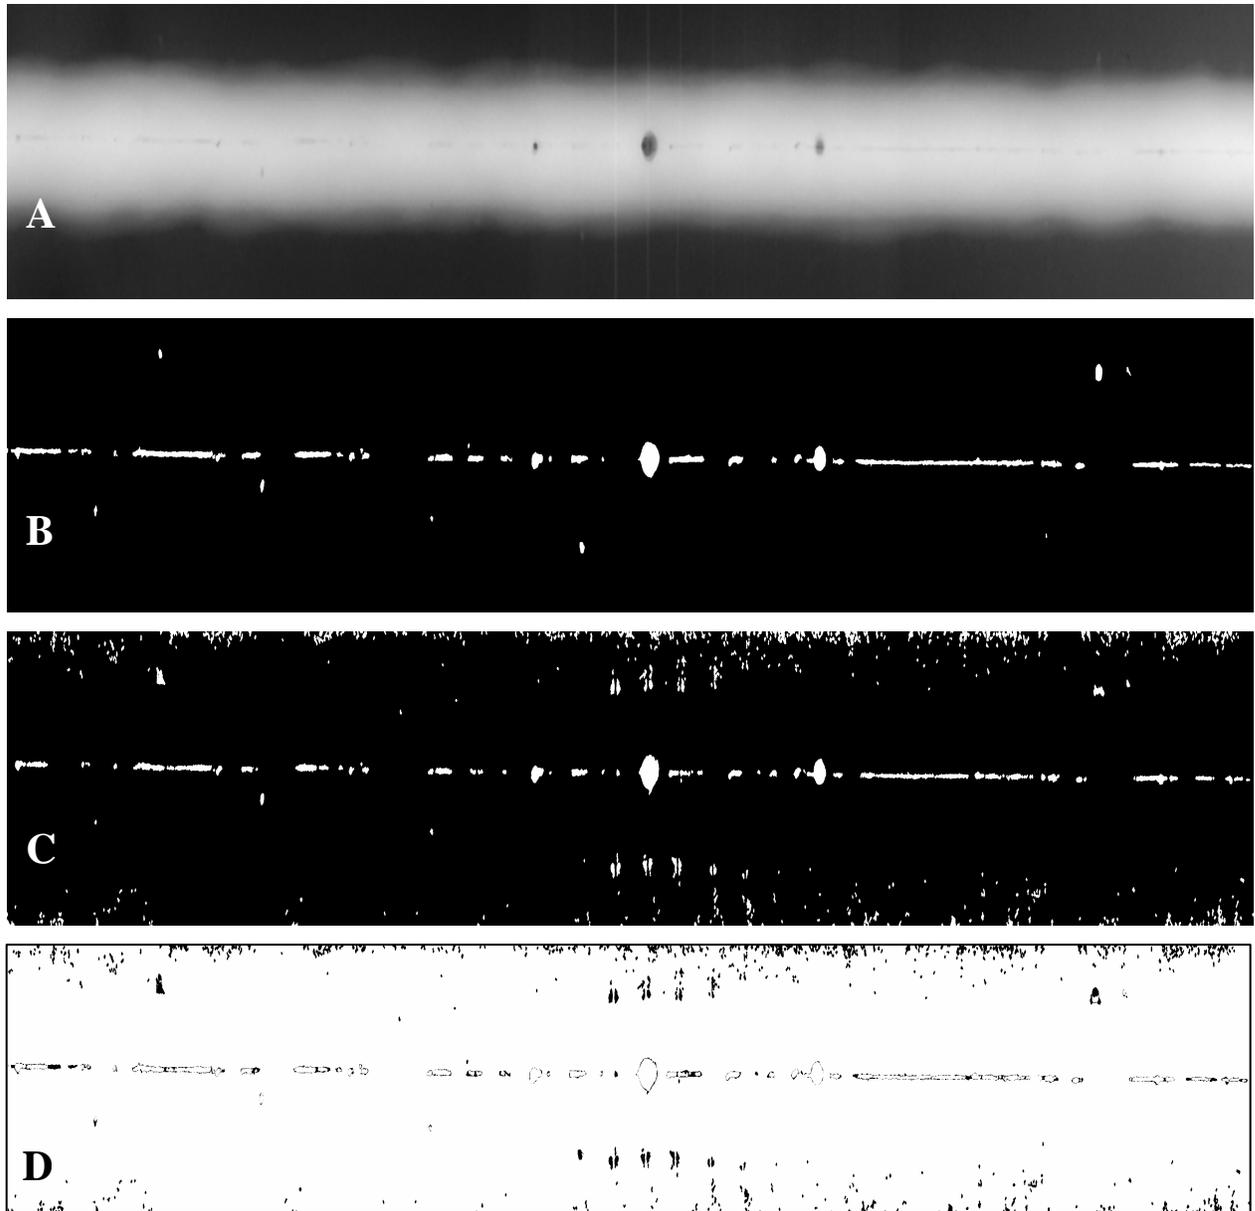


FIGURA 7.5 (a) Imagen original 28R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 4.29%

## 7.9 COMPARACIÓN DE 31R\_M.TIF

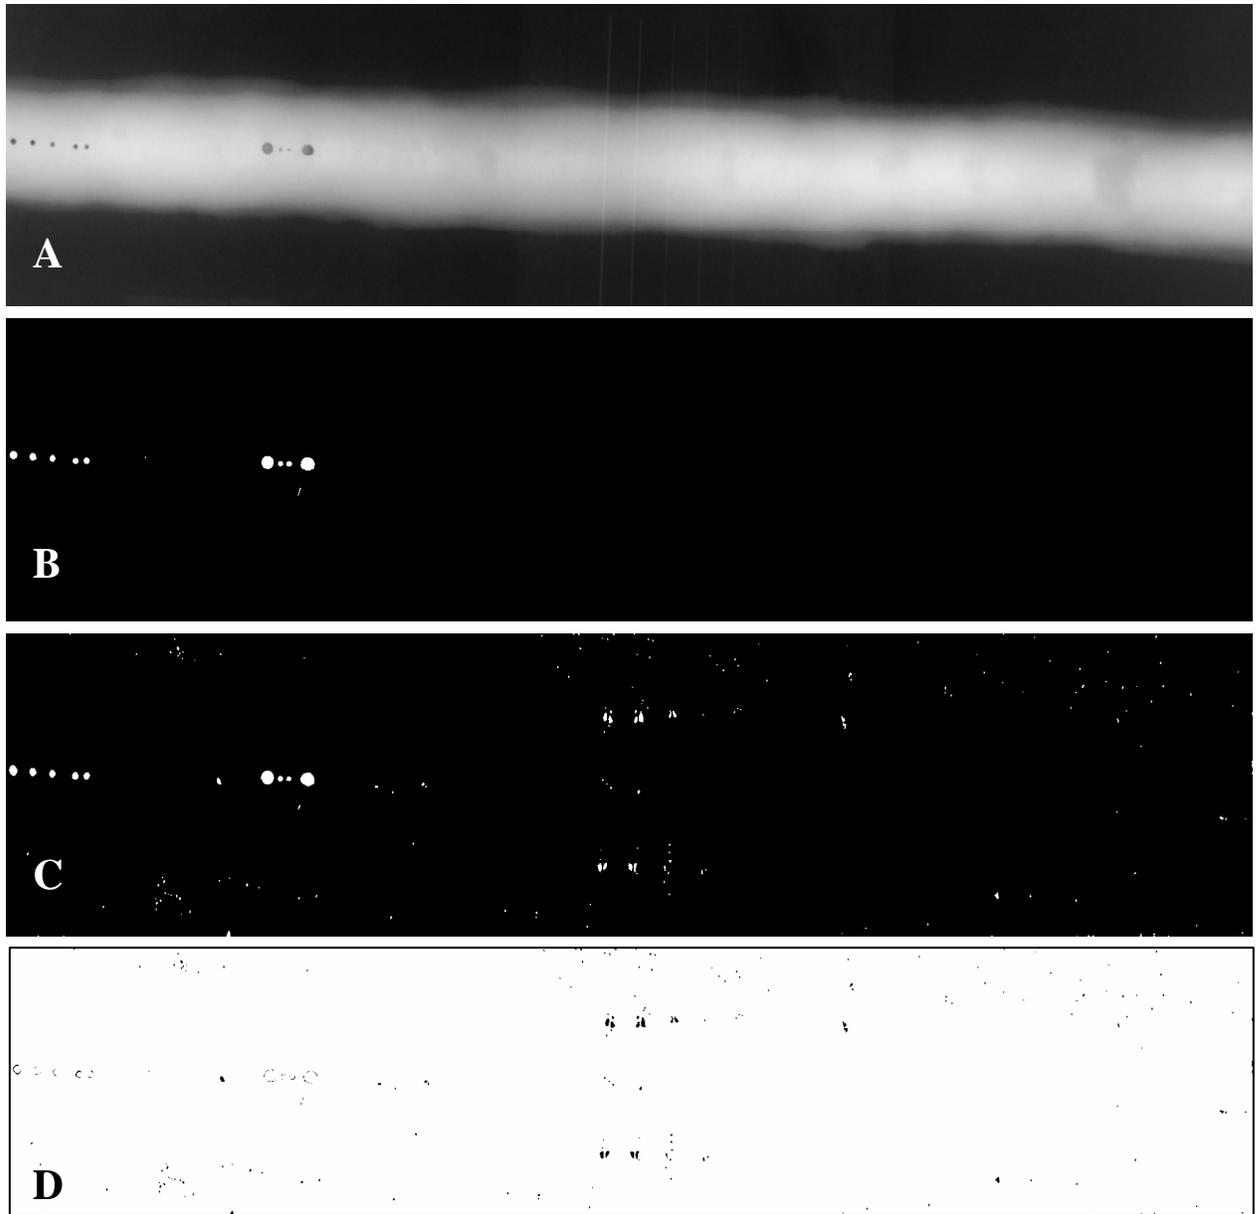


FIGURA 7.6 (a) Imagen original 31R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 0.58%

## 7.10 COMPARACIÓN DE 39R\_M.TIF

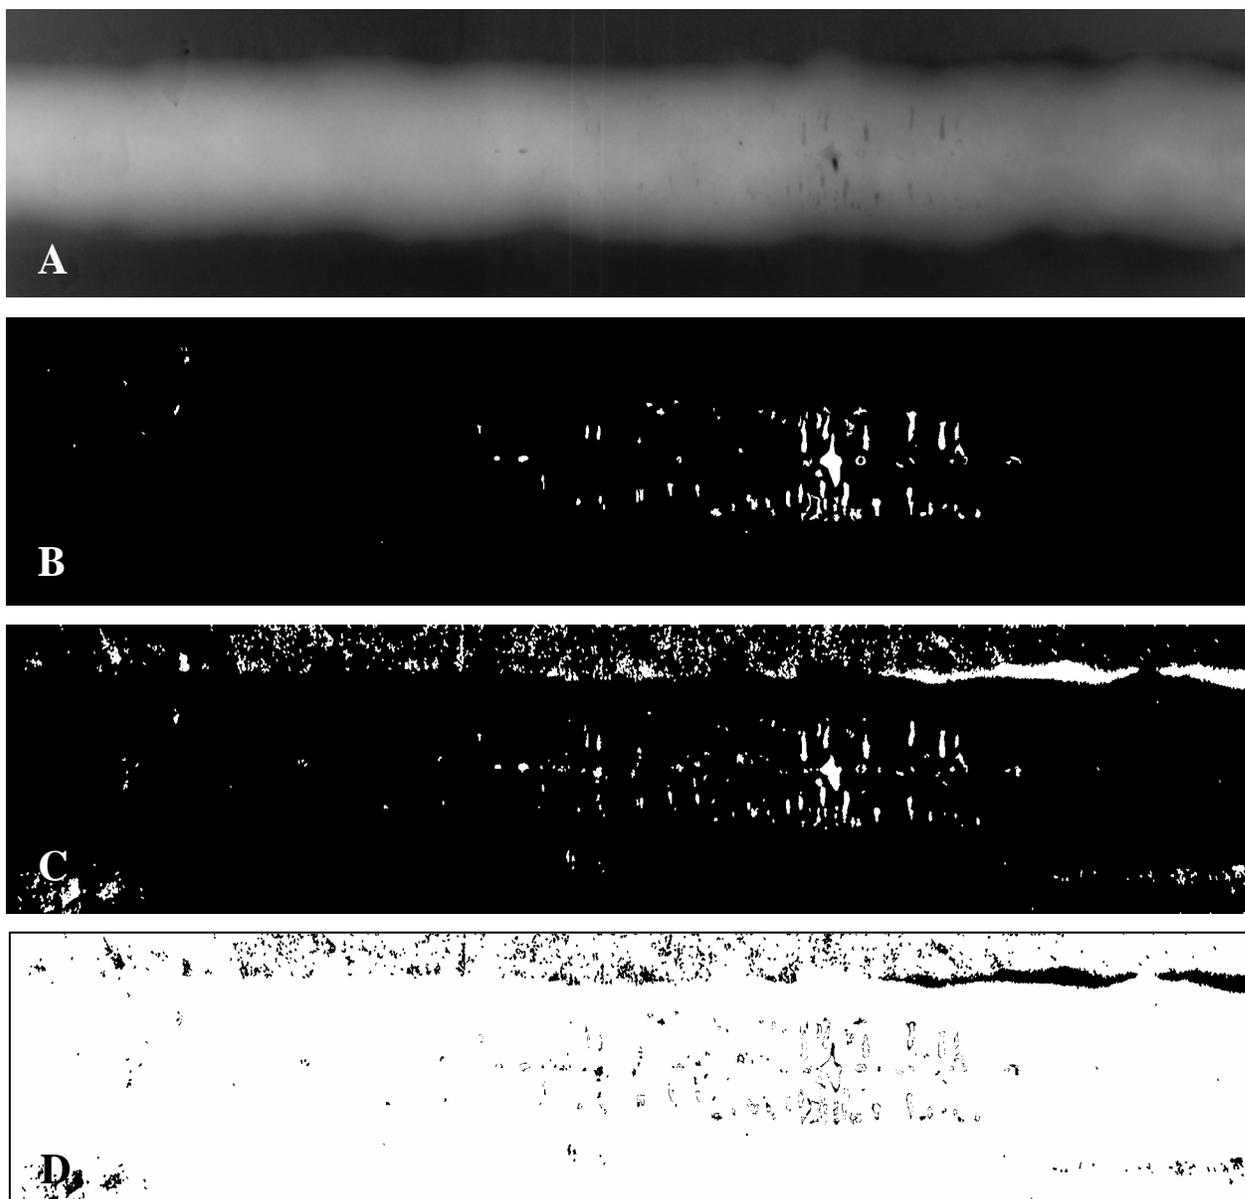


FIGURA 7.7 (a) Imagen original 39R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 7.86%

## 7.11 COMPARACIÓN DE 40R\_M.TIF

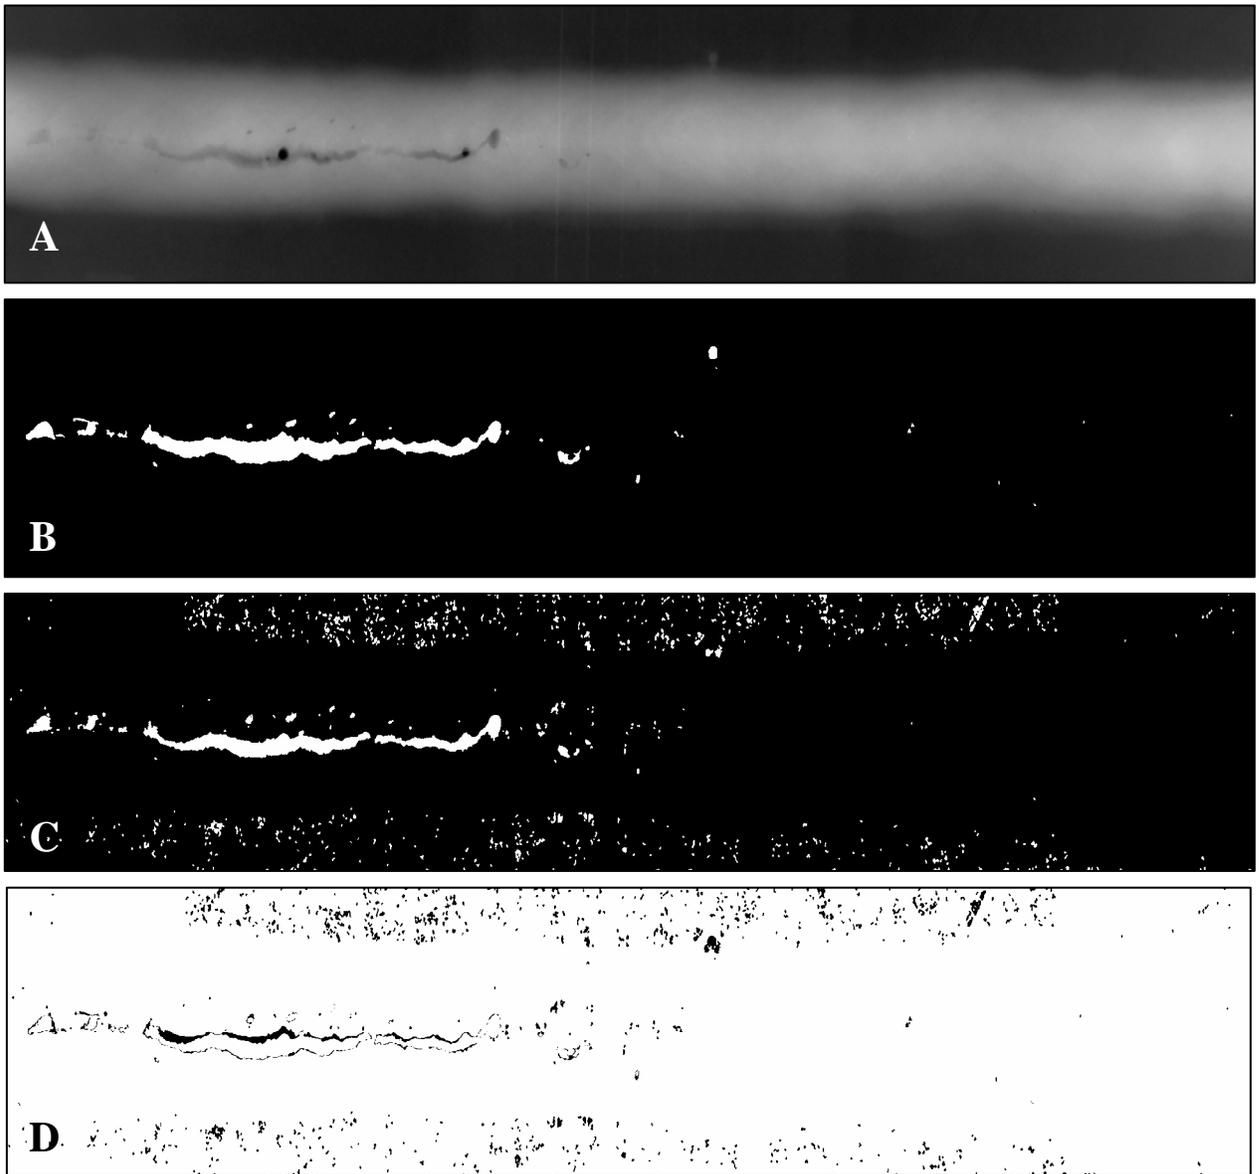


FIGURA 7.8 (a) Imagen original 40R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 3.74%

## 7.12 COMPARACIÓN DE 106R\_M.TIF

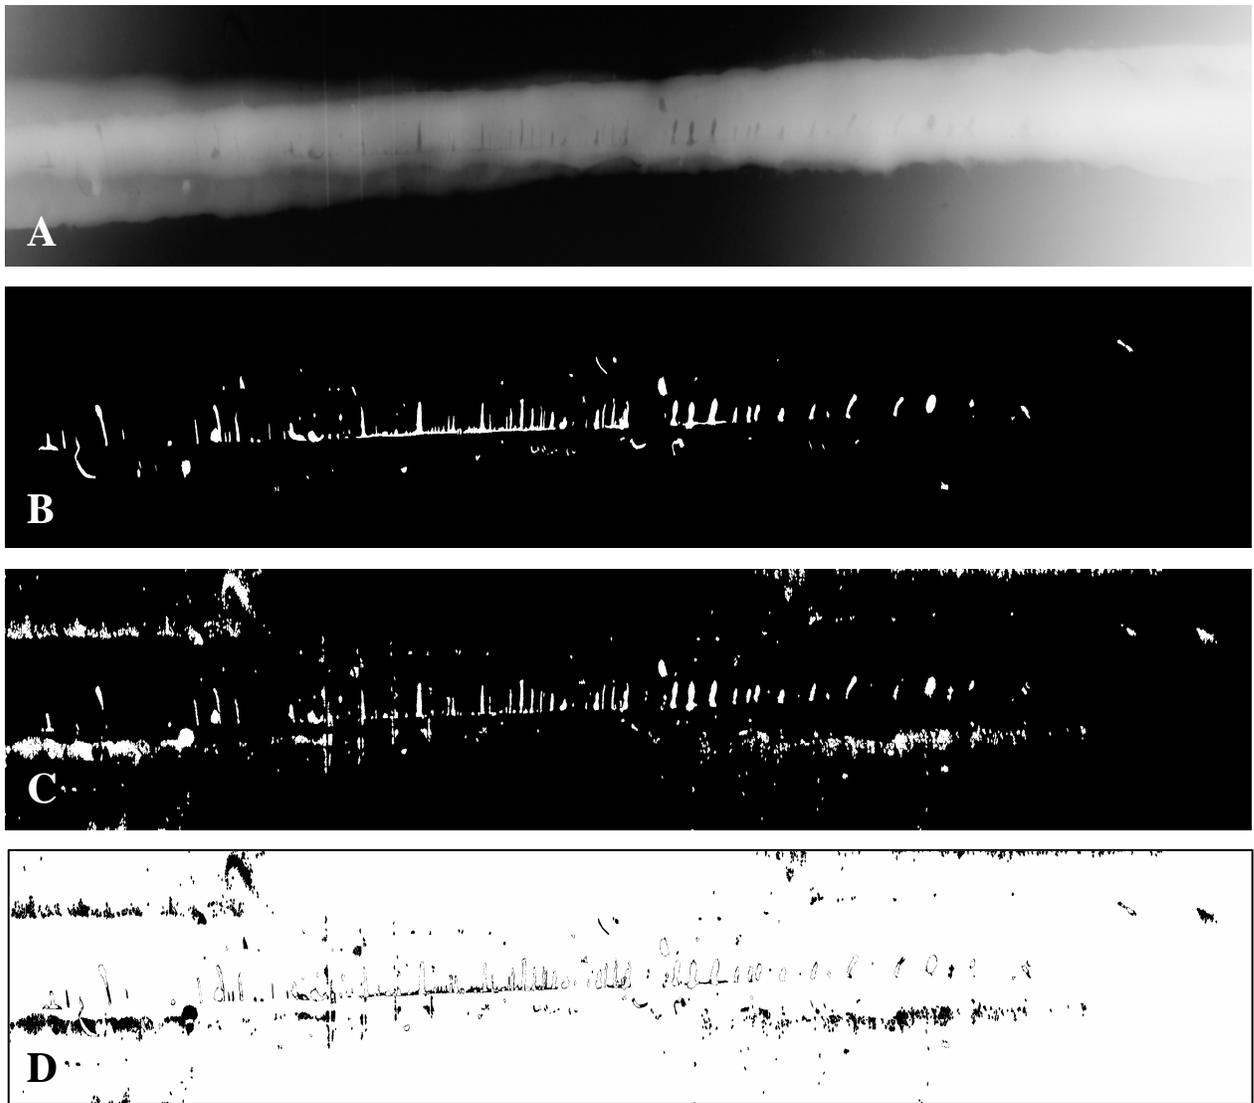


FIGURA 7.9 (a) Imagen original 106R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 6.17%

## 7.13 COMPARACIÓN DE 107R\_M.TIF

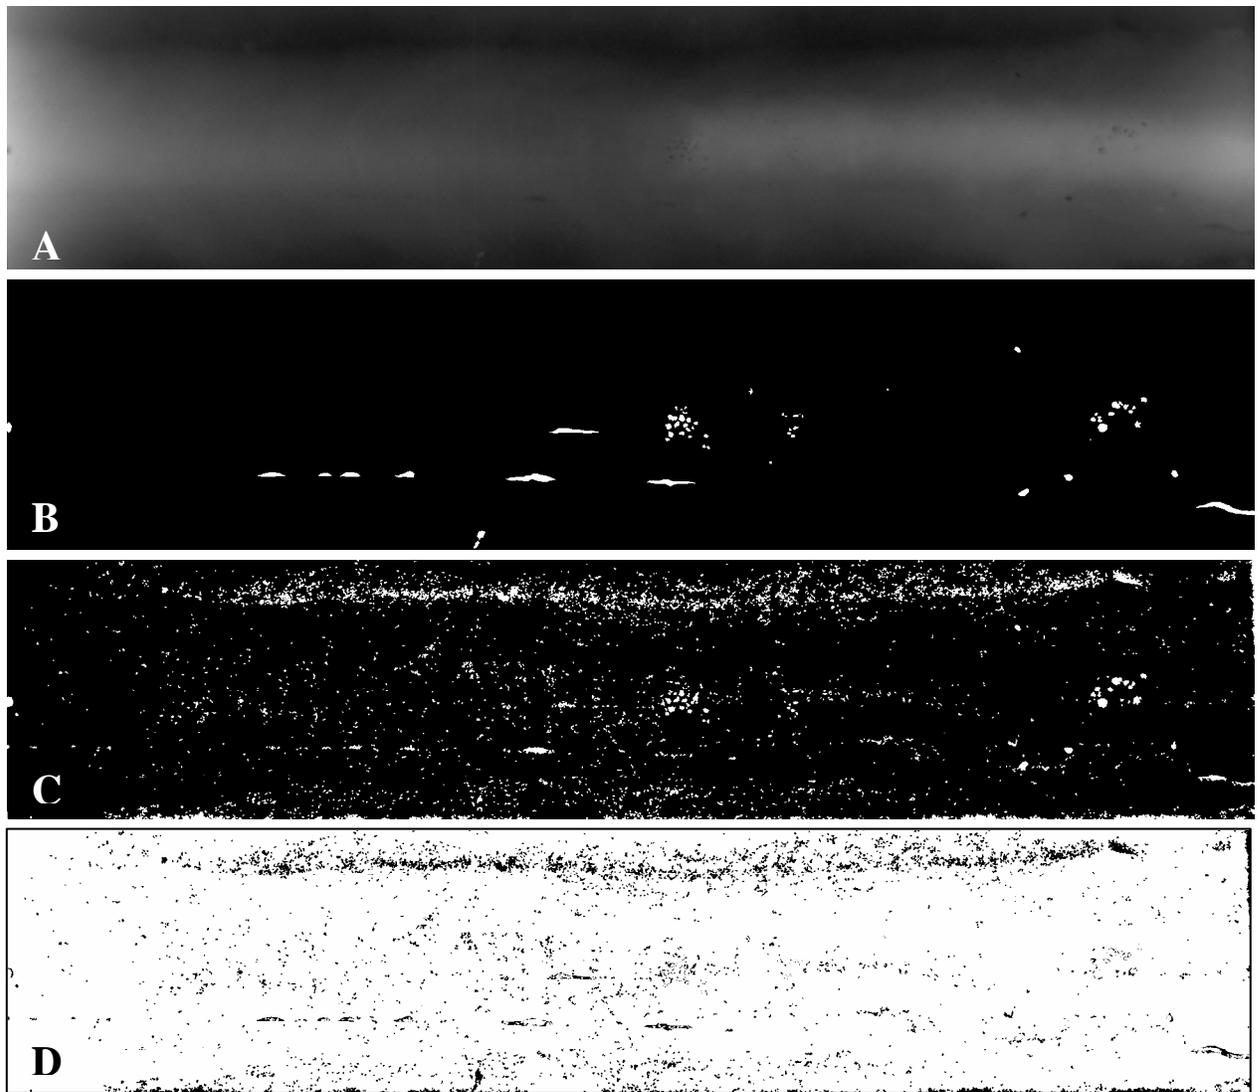


FIGURA 7.10 (a) Imagen original 107R\_M.tif, (b) Imagen binaria ideal de fallas de (a),  
(c) Imagen segmentada con el método propuesto,  
(d) Diferencia absoluta entre las imágenes  $|B-C|$  error de 10.96%