

Universidad Politécnica de Cartagena

**AUTOMATIZACIÓN DE LA  
INSPECCIÓN DE IMÁGENES  
RADIOGRÁFICAS DE UNIONES  
SOLDADAS: SOLUCIONES  
EFICIENTES BASADAS EN  
CLASIFICADORES  
NEURONALES**

Autor: Rafael Vilar Hernández

Directores: Juan F. Zapata Pérez  
Ramón Ruiz Merino

2010



A Carmen  
A mis padres  
A mi familia



---

## Agradecimientos

---

Como casi todas las Tesis Doctoral, esta también es deudora de muchas personas y circunstancias imposibles de enumerar. Destacaré en primer lugar la labor realizada por mis directores Juan F. Zapata Pérez y Ramón Ruiz Merino a quienes debo sin duda la culminación de este trabajo. Debo admitir que al final del camino me irrité bastante cuando recibí sus extensas listas de cosas que debían ser cambiadas o corregidas. Estoy seguro que esta Tesis ha mejorado mucho gracias a que mi hicieron trabajar sin descanso.

Asimismo agradecer muy especialmente la inestimable ayuda del Departamento de Electrónica, Tecnología de Computadoras y Proyectos, a la institución y a todos sus miembros, por acogerme desde el principio con los brazos abiertos. Mi sincera gratitud a todos ellos.

Finalmente, no voy a olvidar a mi familia, mi madre, mi hermana y sobre todo a Carmen mi compañera. Siempre han estado a mi lado, sin reproches, sin premuras con cariño.

Gracias.



Imagine there's no countries  
It isn't hard to do  
Nothing to kill or die for  
And no religion too  
Imagine all the people  
Living life in peace...  
Imagine  
John Lennon



---

## Resumen

---

La inspección radiográfica de uniones soldadas constituye una técnica de control de calidad que hoy día se ha hecho indispensable en sectores industriales como el nuclear, naval, químico o aeronáutico, siendo particularmente importante en aplicaciones críticas en las que un fallo en una soldadura puede resultar catastrófico.

El problema de la inspección radiográfica presenta, en general, un alto nivel de complejidad, lo que ha condicionado que esta tarea sea llevada a cabo en exclusiva por expertos que basan la eficiencia de su dictamen en la experiencia obtenida del examen de casos similares a lo largo de años.

La dificultad de disponer de expertos capaces de identificar y valorar los defectos en uniones soldadas, y lo costoso del proceso de formación, justifican los esfuerzos de automatización en este campo. Sin embargo, el deseable desarrollo de sistemas para incrementar la objetividad, consistencia, precisión y eficiencia de la inspección radiográfica, choca con el obstáculo de tener que traducir las impresiones subjetivas del experto en información computable.

Precisamente en el campo de la automatización de la inspección de imágenes radiográficas de uniones soldadas se sitúa esta Tesis Doctoral, cuyo objetivo puede resumirse en el estudio, implementación y validación de un conjunto de técnicas dirigidas a dicha automatización, con especial énfasis en la aplicación de soluciones de *soft-computing* para resolver el problema de la clasificación de defectos. En este sentido, como parte de la etapa de preprocesamiento, hemos implementado técnicas eficientes para la atenuación del ruido, mejora del contraste y realce de las características discriminantes. Para acometer la tarea de la delimitación del cordón de soldadura se han desarrollado e implementado tres procedimientos. El primero de ellos utiliza información local extraída de ciertos perfiles de la imagen radiográfica para, mediante la aplicación de técnicas de umbralización adaptativa, e introduciendo conocimiento del dominio, superar los inconvenientes asociados a las técnicas de umbralización fija. La segunda propuesta se sitúa en el campo de la interpretación de imágenes basada en conocimiento, y en ella el proceso de análisis se realiza en tres niveles de abstracción, en los que se va inyectando de forma progresiva conocimiento del dominio. El tercer procedimiento para la segmentación del cordón de soldadura aplica técnicas de umbralización óptima y etiquetado de componentes conectados. Precisamente esta última propuesta es la que se ha utilizado para la detección y delimitación automática de las heterogeneidades. Se ha desarrollado e implementado un procedimiento en dos etapas para la selección de un conjunto de propiedades relevantes de las heterogeneidades detectadas para su posterior clasificación. Finalmente, se proponen dos soluciones a la tarea de clasificación de los

defectos, por un lado se utiliza un clasificador no lineal basado en una red neuronal artificial (ANN), bajo tres procesos de regularización con diferentes arquitecturas y en donde se utiliza la técnica de análisis de componentes principales para reducir en la capa de entrada el número de variables, y se analizan la utilización de diferente número de neuronas en la capa oculta, para conseguir en ambos casos el mejor rendimiento en el proceso de clasificación. Por otro lado, se utiliza una red adaptativa basada en un sistema de inferencia neuro-borroso (ANFIS). En este caso, todas las posibles combinaciones de los patrones de entrada tomados de cuatro en cuatro son la entrada del sistema, y se comprueba que patrón permite un mejor rendimiento en la clasificación.

De cara a conseguir los mejores resultados de clasificación, se ha analizado el rendimiento de la ANN y del ANFIS mediante un análisis de regresión entre la respuesta de las redes y los objetivos de clasificación, variando en el primer caso la configuración de la red neuronal y en el segundo el vector de entrada. Los resultados de precisión obtenidos con la mejor configuración de la ANN, a partir de la matriz de confusión, arrojan un valor de 0.78.

El segundo clasificador desarrollado, ANFIS, dividido en cinco secciones, una por cada clase de heterogeneidad, ha obtenido una precisión del 0.82 para el conjunto, lo que supone que este clasificador mejora ligeramente los resultados de precisión del clasificador basado en una red neuronal artificial.

---

## Abstract

---

Radiographic inspection of weld joints is a quality control technique. Nowadays, it has become indispensable for industrial sectors such as nuclear, naval, chemical, or aircraft; being particularly important in critical applications where a failure in the weld joint can become catastrophic.

Generally, the problem of radiographic inspection has a high level of complexity. It has determined this task to be carried out exclusively by specialist experts who base their decisions on their opinions and the experiences of review in similar cases over the years.

The difficulty of having experts capable of identifying and evaluating weld defects, and the expense of the training process, justify automation efforts in this field. However, the desirable development of systems to improve the objectivity, consistency, accuracy and efficiency of the inspection radiographic, collides with the obstacle of having to translate the expert subjective impressions into computable data.

This thesis is particularly focused on the field of automatic inspection of the radiographic image of welded joints. Its aims can be summarised in the study, implementation and validation of a set of techniques for this automation, with special emphasis on the application of soft-computing solutions to solve the problem of the classification of defects. In this sense, as part of the preprocessing stage, we have implemented efficient techniques for noise reduction, contrast and discriminating characteristics enhancement. Three procedures have been developed and implemented to undertake the task of defining the weld region. The first proposal uses some local information extracted from the radiographic image profiles for overcoming the disadvantages associated with fixed thresholding techniques. This is achieved by applying adaptive thresholding techniques and introducing some domain knowledge. The second proposal is registered in the field of image interpretation based on knowledge. The analysis process is performed in three abstraction levels, which will gradually inject the domain knowledge. The third proposal for segmentation of the weld regions applies optimal thresholding techniques and connected components labelling. Precisely, this latter proposal itself has been used for automatic detection and delineation of the heterogeneity. We have developed and implemented a two-step procedure for selecting a set of relevant properties of identified heterogeneities for further classification. Finally, we propose two solutions for the task of classification of defects. The first one uses a non-linear classifier based on artificial neural network (ANN), under three regularisation processes with different architectures and where is used principal component analysis technique to reduce the number of

variables in the input layer, and discusses the use of numbers different of neurons in the hidden layer to achieve both the best performance in the classification process. On the other hand, an adaptive network uses a system based on a neuro-fuzzy inference system (ANFIS). This time, the inputs of the system are groups of four input patterns made from all their possible combinations. The aim is obtaining a pattern for a better performance in classification.

We have analysed the performance of the ANN and ANFIS using a regression analysis between the response of the networks and classification targets in order to achieve the best classification results. This task has been performed by varying the neural network configuration, for the first case, and varying the input vector, for the second one. Accuracy results obtained with the best configuration of the ANN, from the confusion matrix, show a value of 0.78.

The second classifier developed, an ANFIS which is divided into five sections, one for each class of heterogeneity, obtained an accuracy of 0.82 for the set. It means that this classifier slightly improves the results of the classifier based on an artificial neural network.

---

## Índice general

---

Índice de figuras	xv
Índice de tablas	xxi
Índice de algoritmos	xxiii
1 La Imagen Radiográfica de Uniones Soldadas	1
1.1 Calidad de las Imágenes Radiográficas	1
1.1.1 Contraste Radiográfico	1
1.1.2 Definición Radiográfica	3
1.1.3 Densidad Radiográfica	4
1.2 Evaluación de la Calidad de las Imágenes Radiográficas	5
1.2.1 Indicadores Tipo Hilo	6
1.2.2 Indicadores Tipo Escalerilla	6
1.2.3 Indicadores Tipo Placa Taladrada	7
1.2.4 Comentarios Finales sobre Indicadores	7
1.3 Defectos Detectables en Radiografías de Uniones Soldadas	8
1.3.1 Discontinuidades Internas	11
1.3.2 Discontinuidades Externas	15
1.3.3 Ejemplos de Defectos	19
1.4 Sumario	20
2 Sistemas Automáticos de Inspección ...	25
2.1 Adquisición de las Imágenes	25
2.2 Preprocesado de las Imágenes	27
2.3 Segmentación del Cordón de Soldadura	28
2.4 Segmentación de Defectos	31
2.5 Extracción y Selección de Características	38
2.6 Identificación y Clasificación de Defectos	43
2.7 Sumario	48
3 Reconocimiento de Patrones mediante ANN y ANFIS	53
3.1 Reconocimiento de Patrones	53
3.2 Reconocimiento de Patrones mediante Redes Neuronales Artificiales (ANN)	56
3.2.1 Modelo de Neurona	57

3.2.2	Topología de una Red . . . . .	60
3.2.3	El Proceso de Aprendizaje . . . . .	61
3.2.4	Perceptrón . . . . .	64
3.2.5	Algoritmos de Aprendizaje para el Perceptrón Multicapa . . . . .	67
3.3	Lógica Borrosa y Reconocimiento de Patrones mediante ANFIS . . . . .	71
3.3.1	Taxonomía de la Incertidumbre . . . . .	72
3.3.2	Fundamentos de la Lógica Borrosa . . . . .	73
3.3.3	Inferencia borrosa. Reglas de implicación. . . . .	77
3.3.4	Sistemas de Inferencia Borrosa . . . . .	79
3.3.5	Sistemas de inferencia ANFIS . . . . .	81
3.4	Sumario . . . . .	87
4	Metodología de Análisis de las Imágenes Radiográficas . . . . .	89
4.1	Adquisición de las Imágenes . . . . .	89
4.2	Preprocesamiento de las Imágenes . . . . .	90
4.2.1	Reducción-Eliminación de Ruido. Filtrado . . . . .	91
4.2.2	Ajuste de Intensidades . . . . .	95
4.3	Segmentación del Cordón de Soldadura . . . . .	99
4.3.1	Técnica de Segmentación Basada en Perfiles . . . . .	101
4.3.2	Técnica de Segmentación Progresiva . . . . .	105
4.3.3	Técnica de Segmentación Basada en Etiquetado de Componentes Conectados . . . . .	119
4.4	Segmentación de Heterogeneidades Candidatas a Defectos . . . . .	130
4.5	Extracción de Características . . . . .	133
4.5.1	Selección de Características por Categorías Morfológicas . . . . .	136
4.5.2	Selección de Características mediante Análisis de Componentes Principales (PCA) . . . . .	139
4.6	Clasificación de Defectos . . . . .	143
4.6.1	Clasificación de Defectos Utilizando una Red Neuronal Artificial Multicapa Retro-alimentada (ANN) . . . . .	144
4.6.2	Clasificación de Defectos Utilizando un Sistema Adaptativo de Inferencia Neuro-Borrosa (ANFIS) . . . . .	158
4.7	Sumario . . . . .	168
5	Resultados y Discusión . . . . .	173
5.1	Segmentación de Cordones de Soldadura . . . . .	177
5.2	Segmentación de Heterogeneidades Candidatas a Defectos . . . . .	178
5.3	Clasificación Mediante Red Neuronal Artificial Multicapa . . . . .	181
5.4	Clasificación Mediante Sistema Adaptativo de Inferencia . . . . .	190
5.5	Discusión de los Resultados . . . . .	192
	Conclusiones y Principales Aportaciones . . . . .	199
A	Resultados de las Etapas de Segmentación . . . . .	203
	Bibliografía . . . . .	235
	Índice alfabético . . . . .	245

---

## Índice de figuras

---

1	Sistema de inspección automática. . . . .	xxix
1.1	Contraste y definición radiográfica. . . . .	2
1.2	Curva característica de película radiográfica. . . . .	4
1.3	Indicador de calidad de imagen tipo hilo. . . . .	6
1.4	Indicador de calidad de imagen tipo escalerilla. . . . .	7
1.5	Indicador de calidad de imagen tipo placa taladrada. . . . .	8
1.6	Localización de ICI. . . . .	9
1.7	Imagen radiográfica de unión soldada. A: Identificación entidad de control; B: Indicadores de calidad (ICI); C: Metal base; D: Espesor; E: Identificación de la zona radiografiada; F: Cordón de soldadura. . . . .	10
1.8	Mordeduras internas o de raíz. . . . .	11
1.9	Inclusiones de escorias. . . . .	12
1.10	Inclusiones de Tungsteno. . . . .	13
1.11	Poros aislados. . . . .	13
1.12	Poros agrupados. . . . .	14
1.13	Grietas transversales y longitudinales. . . . .	15
1.14	Falta de penetración. . . . .	15
1.15	Falta de fusión entre capas. . . . .	16
1.16	Fusión incompleta. . . . .	16
1.17	Mordeduras externas o de corona. . . . .	17
1.18	Inclusiones de óxido. . . . .	17
1.19	Rechupe o concavidad interna. . . . .	18
1.20	Unión soldada desalineada. . . . .	18
1.21	Insuficiente reforzamiento. . . . .	19
1.22	Excesivo reforzamiento. . . . .	19
1.23	Imágenes radiográficas con inclusiones de escoria aisladas. . . . .	21
1.24	Imágenes radiográficas con inclusiones de escoria alineadas. . . . .	21
1.25	Imágenes radiográficas conteniendo poros. . . . .	22
1.26	Imágenes radiográficas conteniendo grietas. . . . .	22
1.27	Imágenes radiográficas conteniendo falta de penetración. . . . .	23
1.28	Imágenes radiográficas conteniendo falta de fusión. . . . .	23
2.1	Mejora de contraste mediante extensión dinámica. (a) región de interés; (b) histograma de a. y función LUT; (c) histograma extendido; (d) imagen mejorada. (Nacereddine et al. [75]) . . . . .	29

2.2	(a) Perfil de niveles de imagen radiográfica; (b) Detección de picos y valles de la imagen radiográfica. (Liao y Ni [56]) . . . . .	31
2.3	Proceso de segmentación de defectos propuesto. (Alaknanda et al. [2]) . . . . .	33
2.4	Perfiles de niveles típicos de: (a) cordón de soldadura sin defectos; (b) cordón con defecto pico; (c) cordón con anomalía tipo valle; (d) cordón con anomalía tipo concavidad. (Liao y Li [55]) . . . . .	34
2.5	Esquema de análisis basado en perfiles. (Perner et al. [84]) . . . . .	35
2.6	Arquitectura de la red neuronal. (Nacereddine y Redouane [72]) . . . . .	37
2.7	Definición de características. (Aoki y Suga [4]) . . . . .	40
2.8	Definición de características. (Da Silva et al. [19], [20] y [21]) . . . . .	42
2.9	Definición de características geométricas. (Nacereddine et al. [73] y [74]) . . . . .	44
2.10	Configuración de la ANN utilizada por Nacereddine. (Nacereddine et al. [73] y [74]) . . . . .	47
2.11	Arquitectura de la red neuronal supervisada de Aoki. (Aoki y Suga [4]) . . . . .	47
2.12	Imágenes simuladas de varios tipos de defectos. (Lim et al. [59]) . . . . .	49
3.1	Esquema general de Sistema de Reconocimiento de Patrones. . . . .	55
3.2	Modelo biológico de conexión entre dos neuronas . . . . .	57
3.3	Modelo de neurona con entrada única . . . . .	58
3.4	Modelo de neurona de entrada múltiple . . . . .	59
3.5	Función de transferencia Escalón. . . . .	60
3.6	Función de transferencia Lineal. . . . .	60
3.7	Función de transferencia Logarítmica-sigmoidal. . . . .	61
3.8	ANN con una capa de $S$ neuronas. . . . .	61
3.9	ANN con tres capas. . . . .	62
3.10	ANN con tres capas. (Notación abreviada). . . . .	62
3.11	Proceso de entrenamiento. . . . .	64
3.12	Diagrama de bloques del Perceptrón. . . . .	65
3.13	Perceptrón de una capa de $S$ neuronas. . . . .	65
3.14	Perceptrón de tres capas. . . . .	66
3.15	Patrones de una muestra agrupados en regiones convexas. . . . .	67
3.16	Esquema general de una conexión entre neuronas en un perceptrón multicapa. . . . .	71
3.17	Representación del conjunto de gente joven, según la definición de conjunto clásico. . . . .	74
3.18	Representación del conjunto de gente joven, según la teoría de conjuntos borrosos. . . . .	74
3.19	Representación de funciones de pertenencia triangular y trapezoidal. . . . .	76
3.20	Representación de funciones de pertenencia Gaussiana y campana. . . . .	76
3.21	Representación de funciones de pertenencia sigmoidal y asimétricas. . . . .	76
3.22	Representación de funciones de pertenencia basadas en curvas polinomiales. . . . .	76
3.23	Correspondencia entre los conectivos borrosos y los operadores binarios clásicos . . . . .	78
3.24	Representación gráfica de la relación entre operadores lógicos básicos en lógica clásica y lógica borrosa. . . . .	78
3.25	Una inferencia borrosa con una implicación de un antecedente único. . . . .	80
3.26	Una regla de implicación con múltiples antecedentes. . . . .	80

3.27	Múltiples reglas con múltiples antecedentes. . . . .	80
3.28	Sistema de inferencia borroso (FIS). . . . .	81
3.29	Arquitectura ANFIS, con dos entradas, una salida y cuatro reglas. . . . .	84
3.30	Arquitectura ANFIS: dominio del problema. . . . .	85
4.1	Sistema de inspección automática de imágenes radiográficas. . . . .	90
4.2	Imagen radiográfica digitalizada y abajo su histograma. . . . .	91
4.3	Resultado de la etapa de reducción de ruido mediante filtro Wiener. . . . .	93
4.4	Respuesta frecuencial del filtro Gaussiano. . . . .	95
4.5	Resultado de la etapa de reducción de ruido mediante la aplicación de un filtro Gaussiano. . . . .	96
4.6	Ejemplos de histograma: (a) Bajo brillo; (b) Alto brillo. . . . .	98
4.7	Ejemplos de histograma; (a) Bajo contraste; (b) Imagen saturada. . . . .	98
4.8	Resultado del ajuste de intensidad: arriba imagen procesada; abajo su histograma. . . . .	100
4.9	Transformaciones de histograma para (a) $\gamma = 1$ ; (b) $\gamma > 1$ ; (c) $\gamma < 1$ . . . . .	100
4.10	Segmentación basada en perfiles: ejemplo de extracción de un perfil. . . . .	102
4.11	Algoritmo de segmentación basada en perfiles: esquema de la 1ª fase. . . . .	104
4.12	División de la zona de interés en bandas. . . . .	104
4.13	Algoritmo de segmentación basada en perfiles: esquema de la 2ª fase. . . . .	106
4.14	Aplicación de la 2ª fase de segmentación basada en perfiles sobre la imagen ejemplo. . . . .	106
4.15	Resultado de la segmentación del cordón de soldadura mediante la técnica basada en perfiles. . . . .	106
4.16	Esquema general de la segmentación progresiva. . . . .	108
4.17	Esquema del bloque de bajo nivel de la segmentación Progresiva . . . . .	109
4.18	Influencia del parámetro <i>intervalo mínimo entre centros</i> en el número final de regiones. . . . .	111
4.19	Influencia del parámetro <i>tamaño mínimo de región</i> en el número final de regiones. . . . .	111
4.20	Esquema del bloque intermedio de la segmentación progresiva. . . . .	112
4.21	Ejemplos del proceso de limado de contornos. . . . .	113
4.22	Algoritmo de seguimiento de contornos. . . . .	114
4.23	Ejemplo de restricciones topológicas. . . . .	114
4.24	Ejemplo de funcionamiento de la función <i>better</i> . . . . .	117
4.25	Esquema del bloque alto nivel para la segmentación progresiva. . . . .	117
4.26	Imágenes resultado de: (a) bloque de bajo nivel, (b) bloque de nivel intermedio, (c) bloque de alto nivel. . . . .	120
4.27	Esquema general de segmentación basada en el etiquetado de componentes conectados. . . . .	121
4.28	Vecindad $N_4(p)$ y $N_8(p)$ . . . . .	124
4.29	Imagen binaria ejemplo. . . . .	126
4.30	Aplicación del método de etiquetado de componentes conectados . . . . .	127
4.31	LT: Matriz de Etiquetas Temporales . . . . .	128
4.32	Estructura de datos <i>union-find</i> . . . . .	128
4.33	Aplicación de algoritmo de etiquetado de componentes conectados con estructura de datos <i>union-find</i> . . . . .	129

4.34	Segmentación del cordón de soldadura por etiquetado de componentes conectados: (a) imagen radiográfica; (b) imagen etiquetada; (c) cordón segmentado. . . . .	131
4.35	Imagen sintética mostrando los bordes de los huecos en el interior de los objetos padres, y los objetos hijos. . . . .	132
4.36	Resultados y salida de la aplicación del algoritmo en la imagen sintética.	132
4.37	Resultado de la aplicación del algoritmo de identificación de heterogeneidades sobre la imagen ejemplo: a) Imagen original; b) Cordón de soldadura segmentado; c) Borde del cordón de soldadura superpuesto en la imagen original; d) Objetos etiquetados incluidos en objeto 1 u objeto cordón; e) Objetos incluidos en el cordón de soldadura candidatos a defectos. . . . .	133
4.38	Definición de características. La región la forma los píxeles grises; el rectángulo rojo es el bounding box, y el punto rojo es el centroide. La figura muestra una región y su correspondiente elipse con algunas características; ejes y orientación. . . . .	136
4.39	Imágenes sintéticas representativas de los cuatro tipos generales de formas de defectos. . . . .	138
4.40	Imágenes radiográficas de soldaduras conteniendo defectos. De izquierda a derecha y de arriba a abajo: inclusiones de escoria (radiografía IIW16), grietas longitudinales (radiografía IIW106), poros (radiografía IIW6) y grietas transversales (radiografía IIW46). . . . .	140
4.41	Análisis de la contribución de los componentes principales de las características. . . . .	144
4.42	Tipos de Defectos: $nd$ = no defecto, $si$ = inclusión de escoria, $po$ = porosidad, $tc$ = grieta transversal y $lc$ = grieta longitudinal. . . . .	144
4.43	Selección de elementos de los conjuntos de entrenamiento, validación y test. . . . .	147
4.44	Modelo de neurona y arquitectura de la red . . . . .	148
4.45	Efecto de sobreajuste. . . . .	150
4.46	Regularización con función de rendimiento modificada. . . . .	152
4.47	Regularización <i>Early Stopping</i> . . . . .	152
4.48	Proceso de entrenamiento con algoritmo BFGS sin mejora de la generalización: (a) Evolución del rendimiento; (b) Evolución del error cuadrático medio. . . . .	154
4.49	Proceso de entrenamiento con con algoritmo BFGS y regularización con función de rendimiento modificada: (a) Evolución del rendimiento; (b) Evolución del error cuadrático medio. . . . .	155
4.50	Proceso de entrenamiento con algoritmo BFGS y regularización Bayesiana: (a) Evolución del SSE, SSW y número efectivo de parámetros; (b) Evolución del error cuadrático medio. . . . .	156
4.51	Proceso de entrenamiento con algoritmo Levnberg-Marquardt y mejora de generalización por Detección Temprana ( <i>Early Stopping</i> ): (a) Evolución del rendimiento; (b) Evolución del error cuadrático medio. . . . .	157
4.52	Análisis de regresión de la efectividad de una ANN con tres capas de 10-15-5 neuronas y regularización Bayesiana. . . . .	159

4.53	Análisis de regresión de la efectividad de una ANN con tres capas de 10-15-5 neuronas y regularización Bayesiana. . . . .	160
4.54	Análisis de regresión de la efectividad de una ANN con tres capas de 10-15-5 neuronas y regularización Bayesiana. . . . .	161
4.55	Selección de elementos de los conjuntos de entrenamiento y validación. .	163
4.56	Arquitectura del sistema clasificador de defectos de soldadura basado en ANFIS. . . . .	164
4.57	Funciones de pertenencia finales. . . . .	166
4.58	Curvas de error. . . . .	167
4.59	Salida FIS frente Salida objetivo. . . . .	167
4.60	Análisis de regresión de la efectividad de un ANFIS con vector de entrada formado por las siguientes características: elongación, rectangularidad, excentricidad y <i>solidity</i> . . . . .	169
4.61	Análisis de regresión de la efectividad de un ANFIS con vector de entrada formado por las siguientes características: elongación, rectangularidad, excentricidad y <i>solidity</i> . . . . .	170
4.62	Análisis de regresión de la efectividad de un ANFIS con vector de entrada formado por las siguientes características: elongación, rectangularidad, excentricidad y <i>solidity</i> . . . . .	171
5.1	Ejemplos de imágenes del conjunto calificadas por los expertos. . . . .	174
5.2	Ejemplos de resultados de la etapa de segmentación de cordón utilizando el método de etiquetado de componentes conectados. . . . .	179
5.3	Ejemplos de resultados de la etapa de segmentación de cordón utilizando el método de etiquetado de componentes conectados. . . . .	180
5.4	Ejemplos de resultados de la etapa de segmentación de heterogeneidades candidatas a defecto utilizando el método de etiquetado de componentes conectados. . . . .	182
5.5	Coefficiente de correlación para cada clase de defecto sin mejora de la generalización. . . . .	184
5.6	Coefficiente de correlación para cada clase de defecto con mejora de la generalización mediante función de rendimiento modificada. . . . .	185
5.7	Coefficiente de correlación para cada clase de defecto con regularización Bayesiana. . . . .	186
5.8	Coefficiente de correlación para cada clase de defecto con mejora de la generalización early stopping (bootstrap). . . . .	187
5.9	Coefficiente de correlación medio para todos los tipos de defectos. . . . .	188
5.10	Media para todas las clases de defectos del coeficiente de correlación con diferentes ( $\gamma$ ) en la función de rendimiento modificada. . . . .	195
5.11	Media para todas las clases de defectos del coeficiente de correlación con diferentes ( $\gamma$ ) en la función de rendimiento modificada. . . . .	196
5.12	Coefficientes de correlación para cada clase de defecto y para cada combinación de vector de características . . . . .	197
5.13	Arquitectura de los sistemas clasificadores basados en: (a) ANN y (b) ANFIS. . . . .	198



---

## Índice de tablas

---

2.1 Principales aspectos técnicos de las técnicas utilizadas por los autores citados. . . . .	51
4.1 Valores de características primarias obtenidos para las imágenes sintéticas.	138
4.2 Valores de características obtenidos para las imágenes sintéticas. . . . .	138
4.3 Valores de características obtenidos para los defectos identificados en las imágenes radiográficas reales. . . . .	141
4.4 Ejemplo de vectores de entrada y salida de la ANN. . . . .	146
5.1 Rendimiento de los métodos propuestos para la segmentación del cordón de soldadura. . . . .	181
5.2 Mejores resultados de coeficientes de correlación (C.C.) en función del número de neuronas en la capa de entrada (R) y en la capa oculta ( $S^1$ ), para cada clase de defecto y para cada método de mejora de la generalización. . . . .	189
5.3 Resultados para coeficientes de correlación (C.C.) para las ANN con mejor promedio para cada clase de defectos y para cada método de mejora de la generalización. La capa de entrada es (R) y en la capa oculta es ( $S^1$ ).	189
5.4 Coeficientes de Correlación (C.C.) para diferentes valores de $\gamma$ y un número de neuronas en la capa de entrada (R) y capa oculta ( $S^1$ ) correspondientes a la media para cada clase de defecto . . . . .	191
5.5 Matriz de confusión para la obtención de la precisión de clasificación del sistema basado en ANN con regularización mediante función de rendimiento modificada. (R = 11, $S^1 = 20$ ). . . . .	191
5.6 Algunos coeficientes de correlación obtenidos por ANFIS, para diferentes combinaciones de características. . . . .	193
5.7 Matriz de confusión para la obtención de la precisión de clasificación de la arquitectura ANFIS. . . . .	193



---

## Índice de algoritmos

---

1	Algoritmo de Eliminación de Contornos . . . . .	115
2	Algoritmo de la Función <i>better</i> . . . . .	116
3	Algoritmo de Etiquetado de Componentes Conectados con <i>Union- Find</i> . . . . .	125
4	Algoritmo <i>Find</i> . . . . .	128
5	Algoritmo <i>Union</i> . . . . .	129



---

## Glosario

---

- ADALINE (*Adaptive Linear Neuron/Neurona Adaptativa Lineal*)
- ANFIS: *Adaptative Neuro-Fuzzy Inference System/Sistema Adaptativo de Inferencia Neuro-Fuzzy*
- ANN: *Artificial Neural Network/Red Neuronal Artificial*
- ASME: *American Society of Mechanical Engineering/Sociedad Americana de Ingeniería Mecánica*
- BFGS: *Broyden-Fletcher-Goldfarb-Shanno method*
- BPN: *Backpropagation Network*
- BM: *Base Weld/ Metal Base*
- CC: *Correlation Coefficient/Coeficiente de Correlación*
- CCD: *Charge-Coupled Device*
- CCL: *Component Connect Labelling/Etiquetado de Componentes Conectados*
- CE: *Conjunto de Entrenamiento*
- CTE: *Conjunto de Test de Entrenamiento*
- CV: *Conjunto de Validación*
- CW: *Center Weld/ Centro del cordón*
- DIA: *Defect Identification Algorithm/Algoritmo de Identificación de defectos*
- EMC: *Error Cuadrático Mínimo*
- EW: *Edge Weld/Borde del cordón*
- FIS: *Fuzzy Inference System/Sistema de Inferencia Difuso*
- FP: *Función de Pertenencia*
- IIW-IIS: *International Institute of Welding/Instituto Internacional de Soldadura*
- IQI-ICI: *Image Quality Indicators/Indicadores de Calidad de Imagen*

IW: *Inside Weld/ Interior del cordón*

K-NN: *K-Nearest Neighbour/K-vecino más cercano*

LMS: *Least Minimum Squares/Mínimos Cuadrados*

MF: *Membership Function/Función de Pertenencia*

MLP: *Multi-Layer Perceptron/Multicapa Perceptron*

MSE: *Minimum Squares Error/ Error mínimo cuadrático*

NDT: *Non-Destructive Testing/Ensayos No-destructivos*

PCA: *Principal Component Analysis/Análisis de Componentes Principales*

ROC: *Receiver Operating Characteristics/Características de Rendimiento*

TIG: *Tungsten Inert Gas welding/ Soldadura con gas inerte de Tungsteno*

---

## Preámbulo

---

En las últimas cinco décadas, los métodos de ensayos no destructivos (NDT) han pasado de ser una simple curiosidad de laboratorio a una herramienta indispensable en ingeniería. Con el considerable aumento de la competencia entre industrias, el control de calidad de equipos y materiales se ha convertido en un requerimiento básico para mantener la competitividad en los mercados nacionales e internacionales.

Aunque es una de las técnicas más viejas de ensayos no destructivos, la inspección radiográfica es todavía aceptada como esencial en el control de uniones soldadas en muchos sectores industriales como el nuclear, naval, químico y aeronáutico, siendo particularmente importante en aquellas aplicaciones críticas donde un fallo en la soldadura puede ser catastrófico, como ocurre en depósitos a presión, elementos estructurales de carga en plantas de energía, etc. [26].

Las primeras experiencias para detectar defectos utilizando rayos X tuvieron lugar en el laboratorio de la universidad de Yale en 1896, apenas un año después del descubrimiento de los rayos X por Wilhelm Conrad Röntgen en Alemania. Sin embargo, no fue hasta 1922 cuando fue instalado en el arsenal de Waterton el primer equipo industrial que fue utilizado para la inspección de piezas fundidas. La inspección radiográfica se hizo tan importante que en 1930 la *American Society of Mechanical Engineering* (ASME) aceptó su uso como método de control de calidad de soldaduras en calderas de vapor. Después, durante la segunda guerra mundial, fue utilizado extensivamente para la inspección de buques, submarinos y aeroplanos. Se estima que en Alemania en 1954 alrededor del 50 % de todas las soldaduras de acero de construcción fueron inspeccionadas usando rayos X. Fue en 1975 cuando por primera vez una radiografía fue digitalizada, lo que supuso el comienzo de la inspección automática visual de soldaduras basado en técnicas de procesamiento digital de imágenes.

Para una correcta interpretación de las marcas representativas de una heterogeneidad es necesario disponer de un conocimiento de las características de las piezas a soldar, de las heterogeneidades que pueden presentarse y de los tipos de defectos detectables mediante la inspección radiográfica. Las limitaciones para correlacionar la indicación observada en la imagen y la heterogeneidad que la ha producido vienen supeditadas a la naturaleza de esta última (si se trata de discontinuidades o impurezas), a su morfología (esférica, cilíndrica o plana), a su situación (superficial o interna), a su orientación y a su tamaño. De todo lo apuntado cabe inferir que el problema de la interpretación de radiografías de soldaduras es bastante complejo y requiere de la inyección de conocimiento experto.

Durante la inspección radiográfica, un experto humano se guía mediante pregun-

tas tales como: ¿Es aceptable esta radiografía? ¿Qué son las indicaciones observadas en la radiografía? ¿Cuales de esas indicaciones observadas son anómalas? ¿Que tipo de defectos señalan esas indicaciones anómalas? ¿Resulta esa soldadura con los defectos observados aceptable?.

Responder estas preguntas implica un conocimiento del proceso radiográfico, del proceso de soldadura, de los diferentes defectos que pueden aparecer en una unión soldada y de los estándares y criterios de aceptación. El término conocimiento se enfatiza porque la información utilizada se basa en heurística, perspicacia y una comprensión de la relación entre indicaciones de la radiografía y de los defectos, adquirida a lo largo de muchos años de experiencia.

Las dificultades apuntadas han condicionado que la detección y clasificación de defectos mediante la inspección radiográfica se realice por expertos humanos, inspectores que basan la eficiencia de su dictamen en la experiencia obtenida a partir del examen de casos similares. La dificultad de disponer de expertos para detectar y clasificar de manera fiable los defectos y lo costoso del proceso de formación justifican los esfuerzos de automatización en este campo. El deseable desarrollo de los sistemas para incrementar la objetividad, consistencia, precisión y eficiencia de la inspección se encuentra, sin embargo, con el obstáculo de la necesaria translación de las impresiones del experto en información computable. La mayoría de las veces, las propuestas son inciertas y fruto de un aprendizaje biológico con mecanismos no muy bien conocidos.

En términos generales, un sistema de inspección automática de imágenes radiográficas de uniones soldadas debería tener las etapas que se muestran en la figura 1: digitalización de las radiografías; pre-procesamiento de las imágenes, buscando principalmente la atenuación/eliminación del ruido; mejora del contraste y realce de las características discriminantes; segmentación multinivel de la escena para aislar las zonas de interés (el cordón de soldadura debe ser aislado del resto de los elementos que componen la unión); detección de heterogeneidades; extracción de características discriminantes y, finalmente, clasificación en términos de características individuales y globales.

Las técnicas convencionales de inspección radiográfica implican únicamente un análisis visual de películas radiográficas mediante negatoscopio. Existen diversos factores que influyen en la aceptabilidad de los resultados obtenidos en los ensayos: calidad de la imagen, a su vez influenciada por varios parámetros relacionados con la técnica de inspección, buen funcionamiento del negatoscopio, agudeza visual del inspector, así como su experiencia en interpretación de radiografías [29] y [30].

Durante muchos años, el método convencional de inspección ha sido el único utilizado. Con la progresiva introducción del uso de computadores para la interpretación de las imágenes radiográficas se hace necesario disponer de estas en formato digital. Las imágenes pueden generarse directamente en formato digital mediante sistemas de radiografiado digital o pueden obtenerse mediante un proceso de digitalización de las películas radiográficas.

La calidad de las imágenes radiográficas es un aspecto importante en la detección de los defectos y son muchos los factores que intervienen en que afectan de manera decisiva en la viabilidad de una posterior correcta detección y clasificación de defectos. Incluso cuando la elección de los parámetros ha sido realizada de ma-

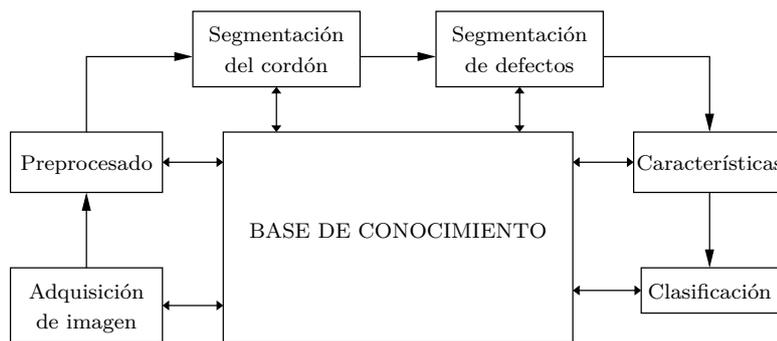


Figura 1: Sistema de inspección automática.

nera cuidadosa, las imágenes pueden presentar problemas tales como la existencia de ruido, iluminación no uniforme y deficiente contraste. Así, por ejemplo, cuando existe un pequeño defecto en el cordón de soldadura puede confundirse con el ruido existente en la imagen originado en la etapa de digitalización o incluso en el proceso de inspección. Todos estos factores hacen que el proceso de inspección de radiografías industriales sea bastante complejo, y que su automatización se aborde desde una diversidad de técnicas cuyo interés se puede constatar en numerosos trabajos.

Dentro de las etapas que conforman un sistema de inspección de uniones soldadas, el proceso de segmentación del cordón de soldadura constituye una fase importante. En esta etapa, hay que aislar el cordón de soldadura del resto de elementos que componen la imagen radiográfica de la unión soldada, con lo que se consigue encuadrar la escena de interés para facilitar las tareas posteriores de detección y clasificación de posibles defectos. Para este objetivo pueden utilizarse diferentes tipos de técnicas de procesamiento o especialistas, dirigidas a la búsqueda de discontinuidades (puntos, líneas y bordes) en la imagen. Sin embargo, esta aplicación presenta una serie de características muy específicas, que hacen que las técnicas genéricas fracasen en su intento de segmentar de forma eficiente el cordón de soldadura en todos los tipos de radiografías de uniones soldadas, y que la fiabilidad del proceso de segmentación dependa de la aplicación de secuencias adecuadas de estos especialistas a partir del conocimiento de los modelos de objetos que pretendemos detectar (conocimiento del dominio).

Una vez aislada la zona de interés, que para nuestro sistema la constituye el cordón de soldadura, debemos abordar quizás la etapa más crítica del proceso, ya que de su fiabilidad van a depender en gran parte las prestaciones del sistema en su conjunto. En esta etapa hemos de detectar con la mayor precisión posible las heterogeneidades presentes en la unión soldada es decir, los candidatos a defectos. Ningún defecto debe quedar sin detectar y el número de falsos positivos no debe ser tan excesivo que llegue a comprometer el rendimiento del sistema desde el punto de vista del tiempo de computación.

Previo al proceso de identificación y clasificación de defectos en las uniones soldadas es necesario extraer un conjunto de características representativas de los mismos. La elección adecuada de las características más relevantes para identificar cada clase de defecto es de importancia fundamental en el proceso de reconocimiento de defectos utilizando sistemas inteligentes. Esta elección se basa en el proceso de

interpretación seguido por un inspector que, la mayoría de las veces, reconoce el tipo de defecto en la imagen radiográfica primeramente por características geométricas y de intensidad (posición, forma, dimensiones, nivel de gris, relación de aspecto, etc), además de observar también las condiciones del proceso de soldadura. Por tanto, es necesario un estudio de la morfología del defecto para optimizar la eficiencia del sistema.

La última etapa de un sistema de inspección de imágenes radiográficas de uniones soldadas corresponde a la tarea de identificación y clasificación de los candidatos a defectos detectados en anteriores etapas. Para ello se aplican técnicas de reconocimiento de patrones basadas en clasificadores estadísticos, redes neuronales y lógica borrosa. No hay una técnica predominante que funcione correctamente en todos los casos, por lo que en muchas ocasiones hay que recurrir a secuencias de especialistas heterogéneos para conseguir unas prestaciones adecuadas en esta última etapa del proceso.

Por último, es necesario señalar la todavía insuficiente investigación en este campo, constatando que aún no existen sistemas comerciales de análisis de radiografías. Es indudable, sin embargo, el creciente número de investigaciones involucradas en el desarrollo de tales sistemas. Es en este campo de la automatización de la inspección de imágenes radiográficas de uniones soldadas donde se sitúa esta tesis doctoral, cuyos objetivos se indican en el siguiente apartado.

## Objetivos

El objetivo general de esta tesis doctoral puede resumirse en el estudio, implementación y validación de un conjunto de técnicas dirigidas a la automatización de la inspección de imágenes radiográficas de uniones soldadas, con especial énfasis en la aplicación de soluciones conexionistas (redes neuronales y sistemas neuroborrosos) para resolver el problema de la clasificación de los defectos detectados. Este objetivo general encierra una serie de objetivos particulares que persiguen el desarrollo de metodologías eficaces para abordar cada una de las etapas de que consta el sistema:

- *Selección, adquisición y digitalización de las imágenes radiográficas.* La calidad de las imágenes radiográficas es un factor importante en el proceso de detección de los defectos. Generalmente esta se evalúa mediante el uso de los indicadores de calidad (IQI). Factores tales como el tipo de película, densidad de la película, distancia focal, nivel de energía de la fuente y tiempo de exposición, afectan de manera decisiva en la viabilidad de una posterior correcta detección y clasificación de defectos. Para asegurar la calidad de las imágenes a utilizar para validar las técnicas a implementar se utiliza la colección de radiografías estándar del Instituto Internacional de Soldadura (IIW). Estos patrones tienen indicaciones de los mas frecuentes clases de defectos que pueden aparecen en uniones soldadas, tales como falta de penetración, porosidades, inclusiones lineales y no lineales de escorias, mordeduras, grietas, etc. Entre ellas se han de seleccionar películas correspondientes a uniones soldadas que contienen las clases de defectos que serán evaluados por el sistema: inclusiones de escoria, porosidad, grietas longitudinales y grietas transversales. La digitalización de estas radiografías se realiza mediante escaner.

- *Pre-procesado de las imágenes radiográficas.* Este pre-procesado se realiza mediante el diseño e implementación de metodologías y técnicas dirigidas, en primer lugar, a la atenuación/eliminación de ruido mediante la utilización de filtros lineales adaptativos que, basados en las características locales de varianza de la imagen, producen un suavizado gradual, actuando sobre las áreas de la imagen donde el ruido es muy aparente, pero manteniendo aquellas áreas donde los detalles deben preservarse y el ruido es menos aparente. En segundo lugar, estas técnicas deben permitir la mejora del contraste y el realce de las características discriminantes con vistas a su interpretación.
- *Segmentación del cordón de soldadura y detección de heterogeneidades.* Como se ha indicado anteriormente, existen motivos para abordar estas etapas con enfoques que utilicen la inyección de conocimiento previo del dominio para superar los problemas presentados. Se propone explorar tres líneas distintas. La primera consistirá en el desarrollo de métodos basados en el análisis de perfiles de intensidad de los niveles de grises transversales al cordón de soldadura. La segunda línea ensayará métodos que asuman el marco formal de interpretación de imágenes basadas en conocimiento con distintos niveles de computación y de utilización implícita y/o explícita del conocimiento del dominio. Por último, se desarrollarán métodos eficientes que apliquen técnicas de umbralización óptima y etiquetado de componentes conectados, completados con una elección de criterios adecuados de selección de regiones.
- *Extracción de características de los candidatos a defectos.* En general, se buscará el conjunto mínimo de características que permitan determinar de manera unívoca a qué clase pertenecen todos los objetos del universo de trabajo y que posibilite la construcción de clasificadores. La elección de una combinación de características que proporcionen la mayor eficiencia para clasificar los defectos de soldaduras, y la forma de evaluar la capacidad de cada característica para discriminar los diferentes tipos de defectos, se puede acometer mediante diversos procedimientos. Para esta tarea realizamos una doble propuesta. La primera sigue la idea de Nacereddine y Tridi [73], en lo referente a la clasificación en categorías de los defectos de acuerdo a sus características morfológicas. La segunda propuesta consiste en la utilización de la técnica de análisis de componentes principales (PCA) para conseguir simultáneamente una reducción en el número de características y la eliminación de información redundante.
- *Clasificación y catalogación de los defectos.* Evidentemente se realizará de acuerdo a las normas internacionalmente aceptadas y utilizando soluciones eficientes basadas en clasificadores neuronales. Para esta última etapa se proponen dos enfoques distintos que se ajustan a soluciones muy de actualidad dentro de las técnicas de clasificación de patrones. Por un lado, utilizaremos el vector de características relevantes obtenido en la etapa anterior como patrón de entrada de un clasificador no-lineal basado en una red neuronal artificial (ANN), y por otro lado dicho vector de características se introducirá en un sistema adaptativo de inferencia neuro-fuzzy (ANFIS).

## Organización de la memoria

La memoria se organiza en cinco capítulos. En el primero de ellos se describen se describen los factores que afectan a la calidad de la imagen radiográfica así como los procedimientos y dispositivos utilizados para su evaluación y se muestra las características y apariencia radiográfica de los distintos defectos que pueden presentarse en cualquier tipo de soldadura.

En el segundo capítulo, se revisan los trabajos más relevantes en relación con la automatización del proceso de inspección, analizando las técnicas y algoritmos utilizados para resolver cada una de las etapas de que constan estos sistemas. En definitiva pretende ser una presentación del estado del arte en estos sistemas.

En el capítulo 3 se hace una introducción a la utilización de redes neuronales artificiales (ANN) y sistemas de inferencia adaptativos neuro-borrosos (ANFIS), como técnicas de clasificación de patrones. No se trata de hacer una revisión exhaustiva del campo del reconocimiento de patrones, ni siquiera de una parte de él, sino más bien de introducir e ilustrar el uso de estas técnicas concretas en la aplicación objeto de nuestro estudio. Se pretende ofrecer las claves para hacer más comprensible una de las partes más destacadas de nuestro trabajo, pero también menos conocidas para los expertos en el campo de los ensayos destructivos y la ingeniería de inspección de equipos.

En el cuarto capítulo se hace una exposición y justificación de las técnicas y algoritmos propuestos e implementados en este trabajo, para resolver cada etapa del sistema de inspección.

En el capítulo 5 se realiza una valoración de las técnicas desarrolladas para la detección y catalogación automática de defectos en imágenes radiográficas de uniones soldadas, se presentan y discuten todos los resultados obtenidos en la resolución de cada una de las etapas que configuran el sistema, resaltando los aspectos más importantes.

Por último, se concluye la memoria presentando las conclusiones y principales aportaciones que a nuestro juicio incorpora este trabajo.

# Capítulo Uno

---

## La Imagen Radiográfica de Uniones Soldadas

---

Durante la inspección radiográfica de una unión soldada, el experto humano trata de, utilizando sus conocimientos sobre el proceso radiográfico, sobre el proceso de soldadura y sobre los diferentes defectos que pueden aparecer en una unión soldada, dictaminar en primer lugar acerca de la aceptación o no de la radiografía, en segundo lugar sobre la naturaleza de las indicaciones observadas y en último término sobre la calidad de la soldadura.

En este capítulo se describen los factores que afectan a la calidad de la imagen radiográfica así como los procedimientos y dispositivos utilizados para su evaluación y se muestran las características y la apariencia radiográfica de los distintos defectos que pueden presentarse en cualquier tipo de soldadura.

### 1.1 Calidad de las Imágenes Radiográficas

La radiografía, como método de inspección, pretende informar sobre la calidad de las soldaduras radiografiadas y, para ello, la imagen producida debe de mostrar la mayor cantidad posible de detalles. Esto implica un control cuidadoso de un número de variables diferentes que pueden afectar a la calidad de la imagen. La sensibilidad radiográfica es una medida de la calidad de una imagen en relación con la capacidad para detectar los detalles o discontinuidades mas pequeñas y depende de la combinación de dos conjuntos independientes de variables que afectan por un lado, al contraste, y por otro lado a la definición de la imagen.

En términos generales, una radiografía es susceptible de aceptación o rechazo en función únicamente de tres parámetros: contraste, definición y densidad radiográfica. A estos parámetros nos refiriremos más extensamente en los siguientes párrafos.

#### 1.1.1 Contraste Radiográfico

El contraste radiográfico es el nivel de diferencia de densidad entre dos áreas en una radiografía. El contraste hace que sea más fácil distinguir características de interés. En la figura 1.1, a la izquierda, se muestran dos radiografías de la misma pieza que presenta una variación brusca de espesor. La radiografía superior tiene un nivel alto de contraste y la inferior posee un nivel bajo de contraste. Aunque ambas imágenes muestran la diferencia en el espesor de la pieza, la imagen de alto contraste utiliza una variación mayor en la densidad radiográfica para indicar este

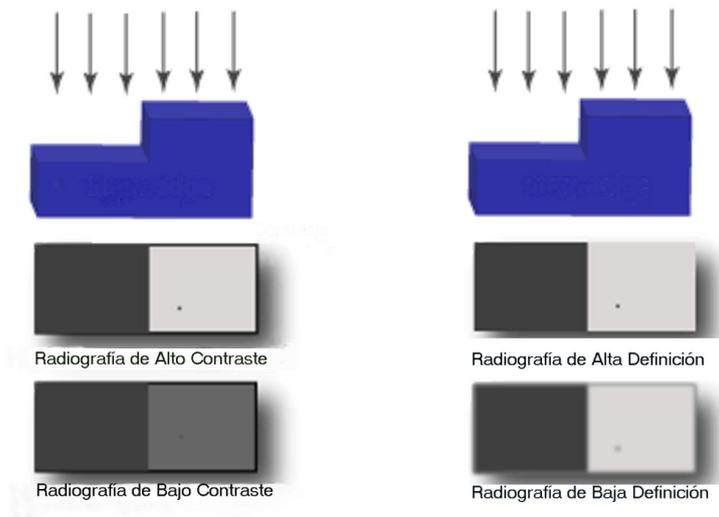


Figura 1.1: Contraste y definición radiográfica.

cambio. En cada radiografía existe un pequeño círculo que resulta mucho más fácil de ver en la radiografía de alto contraste.

El contraste depende de un conjunto de variables que podemos agrupar en factores relacionados con el objeto y factores relacionados con la película radiográfica. El contraste debido al objeto es la relación entre la intensidad de radiación transmitida a través de las diferentes zonas del objeto, la longitud de onda de la radiación primaria, y la intensidad y distribución de la radiación secundaria debida a la dispersión.

La naturaleza del objeto determina la dosis que recibe cada punto de la película de acuerdo con su espesor y capacidad de absorción de la radiación. Los materiales de alta capacidad de absorción tienen un coeficiente  $\mu$  de absorción grande y en ellos se puede poner de manifiesto una mínima variación de espesor, menor que en el caso de materiales menos absorbentes. La sensibilidad de la imagen depende, también, de las características de la radiación empleada en su obtención. En general puede demostrarse teóricamente, y la experiencia lo confirma, que para radiación monocromática el contraste es tanto mayor cuanto menor sea la energía de la radiación. Esto ocurre porque las energías bajas se atenúan más fácilmente. En radiaciones policromáticas, con el mismo rango de energías, el contraste es tanto más alto cuanto más rica en componentes sea la radiación. Como consecuencia de esto los rayos X proporcionan siempre mas alto contraste que la radiación gamma.

Los factores que afectan al contraste y que están relacionados con la película radiográfica se derivan de las diferencias de densidades de la película utilizada, de cómo fue la exposición y de cómo se realizó el procesado.

La figura 1.2 muestra la curva típica de una película radiográfica en donde se aprecia cómo ésta responde a los diferentes valores de exposición. Por la forma de la curva, se puede ver que para valores de densidad bajos la pendiente de la curva es pequeña. En esta región de la curva grandes cambios en la exposición producen un pequeño cambio en la densidad y por tanto la sensibilidad de la película es relativamente baja. Sin embargo, para densidades superiores a 2.0. la pendiente de

la curva característica para la mayoría de las películas es máxima. En esta región de la curva, un pequeño cambio relativo en la exposición se traducirá en un gran cambio en la densidad de la película, por lo que su sensibilidad es alta en dicha región.

### 1.1.2 Definición Radiográfica

La definición de una imagen radiográfica expresa su nitidez, esto es, la aproximación de la imagen real a la que teóricamente correspondería según su geometría. Una imagen mal definida será de límites borrosos y esa borrosidad hará difícil o imposible, según la magnitud de ésta, su estudio. En la parte derecha de la figura 1.1 se muestran dos radiografías, una de alta definición y otra de baja definición. En la de alta definición se puede ver que el cambio en el espesor de la pieza se traduce en un cambio brusco en la densidad radiográfica. Se aprecia que los detalles, particularmente el círculo pequeño, son mucho más fáciles de ver en la radiografía de alta definición. Se puede decir que los detalles representados en la radiografía son equivalentes a los cambios físicos presentes en la pieza. En otras palabras, se ha producido una fiel reproducción visual de la pieza radiografiada. Esto no ocurre en la imagen inferior, donde los bordes de la línea entre los dos espesores son borrosos.

La definición depende de diversos factores que pueden agruparse en factores geométricos del equipo y montaje radiográfico, y factores físicos relacionados con la película y su proceso y dependientes de la técnica. Sabemos que la imagen radiográfica es, en realidad, una sombra proyectada por el objeto sobre la película radiográfica cuando se le ilumina con la radiación penetrante. Sabemos también que las leyes geométricas que rigen la formación de la imagen (ley de ampliación, ley de la penumbra y ley de atenuación por la distancia) están determinadas por factores geométricos como el tamaño de la fuente de la radiación, la distancia entre la fuente y la película y la distancia entre el objeto y el detector, y que, por tanto, influyen de manera determinante en la formación de la imagen. En consecuencia, para conseguir niveles más altos de definición, el tamaño de la fuente debería ser, en la medida de lo posible, lo más próximo a un punto, la distancia fuente-película grande y la distancia objeto-película pequeña.

La incidencia, esto es, el ángulo que la radiación forma con la película también tiene un efecto sobre la definición. Si la radiación es paralela a un borde o discontinuidad lineal, se verá en la imagen una nítida y aguda frontera. Por contra si la radiación no es paralela con la discontinuidad, la indicación aparecerá en la imagen distorsionada, fuera de posición y sin definición.

El último factor geométrico a considerar es la vibración. Cualquier movimiento del objeto, de la fuente o de la película durante la exposición, traerá como resultado una imagen movida y por tanto borrosa y mal definida.

El otro conjunto de factores son los relacionados con la película y la utilización de hojas reforzadoras, filtros y máscaras. Una película de grano menudo es capaz de producir una imagen con mayor nivel de definición que una de grano grueso. La pantallas reforzadoras sintéticas, generalmente de plomo, no mejoran la definición sino el contraste permitiendo un sustancial acortamiento de los tiempos de exposición. Sin embargo, si no están en buen contacto con la película pueden ser causa

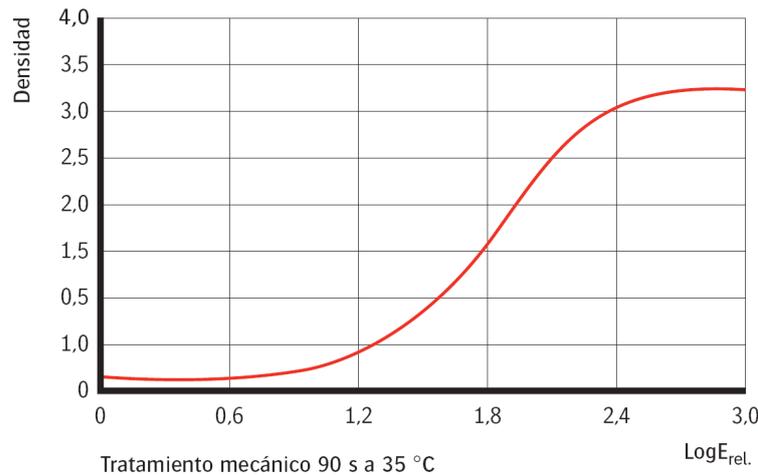


Figura 1.2: Curva característica de película radiográfica.

de considerable borrosidad de los detalles, especialmente de los de menor densidad. En cuanto al grosor de estas pantallas, en general es favorable a la definición cuanto menor sea, si bien esto tiene como contrapartida disminuir los efectos beneficiosos que tienen sobre el contraste. Finalmente, la exposición, producto del tiempo por la intensidad de la radiación, influye en la definición de modo que tiende a hacerla disminuir cuanto más aumenta. Naturalmente, una exposición excesivamente corta, aunque teóricamente proporciona mejor definición, da lugar a una mala densidad.

Dado que el contraste y la definición no dependen del mismo conjunto de factores, es posible producir radiografías con distintas calidades: bajo contraste-pobre definición, alto contraste-pobre definición, pobre contraste-buena definición y alta contraste-buena definición.

### 1.1.3 Densidad Radiográfica

La densidad radiográfica o densidad de película es una medida del grado de oscurecimiento de la película. Se define como el logaritmo de la relación entre la intensidad de luz incidente en la película ( $I_0$ ) y la intensidad de luz transmitida a través de la película ( $I_t$ ).

$$D = \text{Log} \frac{I_0}{I_t} \tag{1.1}$$

Según esta expresión, una densidad de 2.0 significa que sólo un 1% de la luz incidente atraviesa la película, y para una densidad de 4.0 sólo el 0.001% de la luz transmitida atraviesa la cara de la película. Los códigos y normas industriales habituales exigen que las radiografías tengan una densidad comprendida entre 2.0 y 4.0 para ser consideradas como aceptables. Una radiografía puede resultar desechable por alta o por baja densidad. En el primer caso, la razón de su rechazo estriba en la falta de intensidad luminosa del negatoscopio. En cuanto al límite inferior aceptable de densidad, está relacionado con el bajo contraste intrínseco que presentan las películas radiográficas en las zonas de baja densidad. Las mayor parte de las películas

empiezan a presentar un contraste aceptable con densidades del orden de 1.8 a 2.0. Cuando las radiografías van a digitalizarse, son habituales densidades superiores a 4.0 ya que los sistemas de digitalización actuales son capaces de capturar y mostrar imágenes con densidades superiores a 6.0.

## 1.2 Evaluación de la Calidad de las Imágenes Radiográficas

Resulta esencial para quien realiza una radiografía poder demostrar que su trabajo es bueno y, para quien la interpreta, conocer la precisión con que puede percibir los detalles de la imagen, las discontinuidades, defectos, etc, del objeto. Si se coloca sobre el objeto, para que sea radiografiado al mismo tiempo que éste, una pequeña pieza en forma de placa, ésta se comporta como un incremento conocido del espesor del material. Si una vez realizada la radiografía y examinada en condiciones adecuadas puede percibirse la imagen de la placa, es lógico suponer que otro incremento de espesor en la pieza sería también perceptible. Esta pequeña pieza recibe el nombre de *Indicador de Calidad de la Imagen (ICI/IQI)* también conocido como *penetrómetro*.

Si la imagen del ICI rudimentario que estamos considerando se encuentra en el límite de visibilidad del observador, esto es, si resulta distinguible a duras penas sobre la imagen del objeto, es evidente que tal incremento de espesor será el mínimo perceptible. En estas condiciones, este valor mínimo representará un cierto porcentaje del espesor total del objeto, o sea, una sensibilidad de detección. Si llamamos  $E$  al espesor total de la pieza y  $e$  al del ICI, en las condiciones límite antes consideradas la calidad de la imagen ( $S$ ) será:

$$S = \frac{e}{E} \cdot 100(\%) \quad (1.2)$$

A este porcentaje se le llama índice de calidad de imagen, o calidad de penetrómetro de la radiografía, siendo claro que cuanto mayor sea este valor mejor será la calidad de la imagen.

En realidad, la mayor parte de las imágenes de irregularidades del objeto que deben ser interpretadas no corresponden a incrementos de espesor, sino a falta de material (poros, sopladuras, etc), por lo que este criterio no resulta válido a priori. En realidad, habría que sustituir el incremento artificial de espesor del ICI por un agujero taladrado en la propia pieza. Sin embargo, esto no es viable por diversas razones, especialmente por la lentitud del procedimiento y por el deterioro inevitable de la pieza.

Es evidente que cada tipo de discontinuidad en la unión soldada, cuya calidad de imagen radiográfica debe ser contrastada, exigiría un tipo de ICI especialmente concebido para ella. Así, un ICI de hilos, que es muy adecuado para la evaluación de la calidad en las imágenes de pequeñas discontinuidades de morfología esférica (poros), no lo es para la de imágenes correspondientes a fisuras o grietas.

Entre los numerosos ICI que se han propuesto, los de uso habitual que están reconocidos por diversos códigos y normas internacionales (EN 462-1 o EN 462-2) son los de hilo, los de escalerilla y los de placa taladrada.

### 1.2.1 Indicadores Tipo Hilo

Los indicadores de calidad de imagen tipo hilo, como los mostrados en la figura 1.3, son colecciones de hilos de material semejante al del objeto que se radiografía, montados sobre plástico y encerrados en una bolsa transparente de plástico. Los diámetros de los hilos varían de acuerdo con una cierta progresión característica según la norma que se utilice. La lectura se realiza sobre el diámetro del hilo más fino todavía visible en la imagen y cuyo diámetro es perfectamente conocido. A continuación se calcula el tanto por ciento que representa este diámetro respecto al espesor del material mediante la ecuación (1.2).

Como ejemplo, pueden citarse los ICI de las normas DIN que siguen los criterios de IIS/IIW. Hay tres series utilizables para acero al carbono, aluminio y cobre; la primera es válida para fundiciones y aceros no muy aleados, la segunda se emplea asimismo en otras aleaciones ligeras y, por último, la serie de cobre sirve, con suficiente aproximación, para las diversas aleaciones de este material. Sobre una placa del metal correspondiente se encuentran las siguientes inscripciones: DIN/ISO-62, Fe (ó Al ó Cu, según el caso) ó 1-7 (ó 6-12 ó 10-16). Los grupos de hilos de cifras 1-7, 6-12 y 10-16, corresponden a los números de orden de los hilos primero y último de cada ICI.

### 1.2.2 Indicadores Tipo Escalerilla

Como su nombre indica, los indicadores de calidad de imagen de tipo escalera consisten en gradas o escalerillas de altura y espesor conocidos, talladas en un material que tenga una absorción frente a las radiaciones semejante a la que posee el material del objeto que se radiografía. Como se ilustra en la figura 1.4, con esta disposición se tiene una escala de valores de espesores que se traducen sobre la



Figura 1.3: Indicador de calidad de imagen tipo hilo.

imagen en una escala de grises. Para la evaluación de la calidad de la radiografía se determina cual es el escalón más delgado visible en la imagen del ICI y se calcula, con la ecuación (1.2), la sensibilidad de detección que le corresponde.

Existen varias disposiciones, según la norma que se utilice, que han dado lugar a diversos subgrupos de ICI de escalerilla. Así, podemos encontrar escalerillas con taladros de diámetro igual o proporcional al espesor del escalón en que están taladrados y en donde la lectura se realiza determinando el diámetro del agujero más pequeño visible que se corresponde con el espesor del escalón correspondiente.

### 1.2.3 Indicadores Tipo Placa Taladrada

Los indicadores de calidad de imagen tipo placa taladrada, como por ejemplo los que aparecen en la figura 1.5, consisten en pletinas planas, construidas con el mismo material (o muy similar) al del objeto que se radiografía, cuyo grosor está perfectamente determinado, y en las que se han taladrado varios orificios de diámetro creciente, siendo el más pequeño, generalmente, de diámetro igual al espesor de la placa. Para su correcta identificación en la radiografía llevan pegados letras y números de plomo que indican el espesor de la placa así como el material. A la hora de evaluar calidades de imagen es preciso que los tres orificios del ICI sean visibles.

### 1.2.4 Comentarios Finales sobre Indicadores

Hay dos factores importantes relacionados con los ICI que conviene tener siempre presentes;

1. La sensibilidad calculada es función del tipo de ICI utilizado. Una sensibilidad del 2% obtenida con un ICI del tipo hilo no es lo mismo que una sensibilidad del 2% obtenida con un ICI tipo placa taladrada o tipo escalerilla.



Figura 1.4: Indicador de calidad de imagen tipo escalerilla.

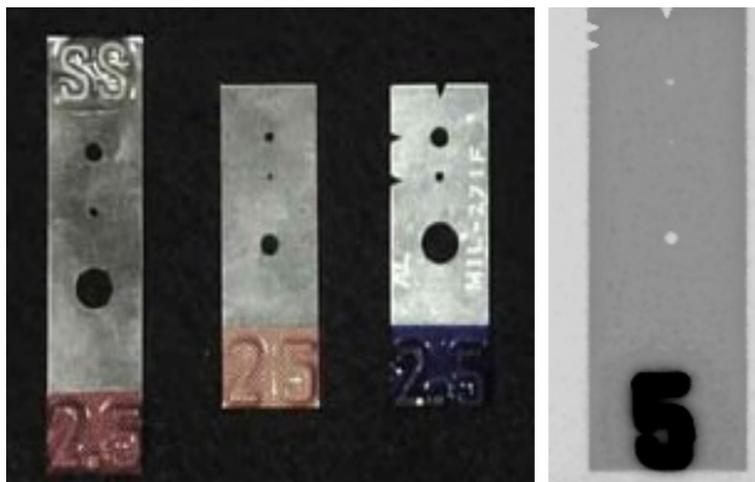


Figura 1.5: Indicador de calidad de imagen tipo placa taladrada.

2. La sensibilidad ICI no es una medida de la discontinuidad más pequeña detectable. La sensibilidad ICI es una medida de la calidad de la imagen, y es un medio de control y evaluación de la calidad.

Una selección correcta del ICI comporta la selección adecuada del metal (acero, aluminio, cobre) y la selección idónea del tipo. Esta última se hará teniendo en cuenta el espesor del objeto a radiografiar, el tipo de energía de radiación a utilizar y el tipo de película. En algunos casos, se especifica un código o norma a emplear que establecerá todos estos factores.

Respecto a la localización del ICI, conviene decir que, según lo dispuesto en la norma EN 1435:1997, estos se deben colocar, siempre que sea posible, sobre el objeto a radiografiar en el lado de la fuente de radiación hacia un extremo del área que va a ser radiografiada y en el metal base adyacente a la soldadura. Para su emplazamiento debe seleccionarse en una sección de espesor uniforme caracterizado por una densidad óptica uniforme en la película. Cuando el ICI esté situado en el lado de la película, debe colarse una letra *F*. De nuevo, decir que en algunos casos se especifica un protocolo de localización específico. La figura 1.6 es un claro ejemplo de este último caso.

### 1.3 Defectos Detectables en Radiografías de Uniones Soldadas

Una vez realizada una radiografía de calidad de la unión soldada, los inspectores han de interpretar lo que muestra la imagen. La interpretación se realiza en tres etapas: (1) detección, (2) interpretación, y (3) evaluación. Todas estas etapas necesitan de la agudeza visual de los inspectores, si bien la capacidad de un individuo para detectar discontinuidades en radiografías está también condicionada por las condiciones de luz del lugar donde se realiza la sesión, y el nivel de experiencia para reconocer diferentes características en la imagen.

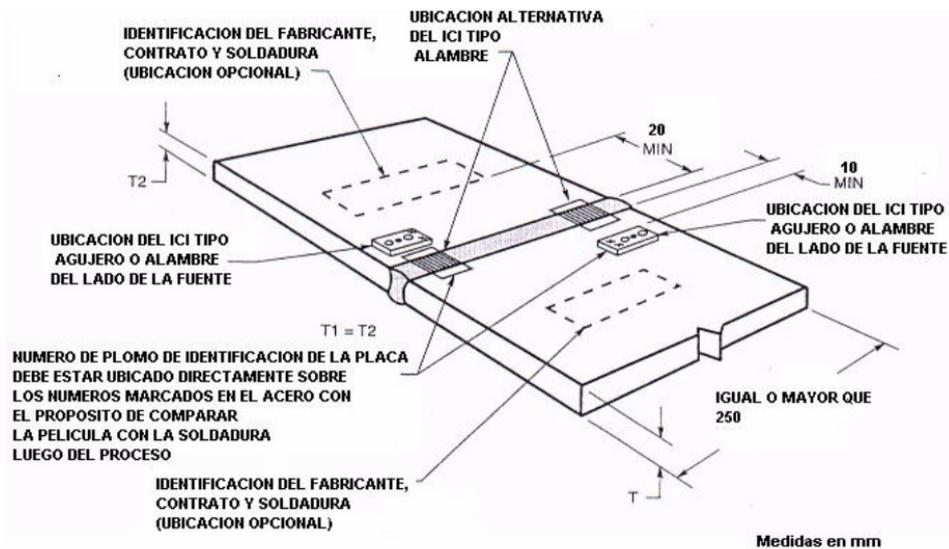


Figura 1.6: Localización de ICI.

Como dijimos anteriormente, la interpretación consiste en hallar la correlación entre la indicación observada en la imagen con la naturaleza propia de la heterogeneidad o de la anomalía; es el dictamen sobre qué es lo que da motivo a una indicación.

En general, no existen reglas que puedan seguirse para realizar la interpretación de radiografías, aunque si nos basamos en las leyes de absorción de radiación, se pueden establecer algunos principios:

1. Las zonas relativamente más claras corresponden a materiales de mayor número atómico, o zonas de mayor espesor del material.
2. Las zonas oscuras se corresponden con materiales más densos o zonas más delgadas de un material no homogéneo.
3. La mayor parte de las heterogeneidades consideradas como defectos van a ser debidas a discontinuidades (falta de material) o inclusiones (impurezas) de materiales menos densos. En ambos casos las indicaciones aparecerán como objetos relativamente oscuros. Si las inclusiones son de material más denso, tales como las de volframio en soldaduras TIG, ocurrirá lo contrario.

Para que una heterogeneidad, impureza, discontinuidad o imperfección, sea detectable radiográficamente es preciso que se cumplan dos condiciones:

1. Que la heterogeneidad presente un coeficiente de absorción diferente del material en que se encuentre.
2. Que presente una dimensión suficiente en la dirección del haz de radiación.

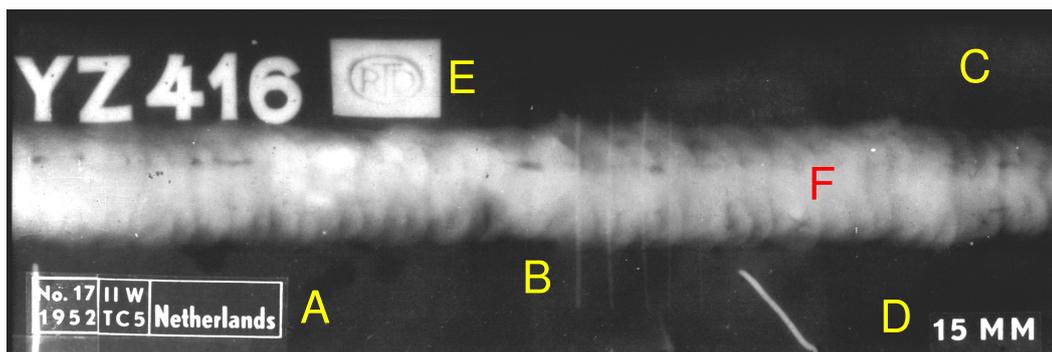


Figura 1.7: Imagen radiográfica de unión soldada. A: Identificación entidad de control; B: Indicadores de calidad (ICI); C: Metal base; D: Espesor; E: Identificación de la zona radiografiada; F: Cordón de soldadura.

En la figura 1.7 se muestra un ejemplo de imagen digitalizada de una unión soldada, con la intención de describir la apariencia de una radiografía industrial utilizada habitualmente en un proceso de control de calidad mediante NDT. Como se puede apreciar, existen distintos objetos que componen la imagen de una unión soldada. Por un lado aparece lo que se conoce como metal base, es decir, las dos piezas que se unen mediante el aporte de un material, y por otro lado aparece el cordón de soldadura, es decir, la costura de unión formada mediante elevación de la temperatura del metal de aporte que se funde junto con los bordes del metal base. Sobre estos elementos se disponen otros objetos cuya finalidad consiste en identificar: el espesor de las piezas a unir, la localización de la soldadura radiografiada dentro del conjunto y de la obra y la entidad de control de calidad que realiza la inspección. Asimismo, sobre el cordón de soldadura se disponen los indicadores de calidad de la imagen. Por último, y lo más importante, dentro del cordón de soldadura aparecen las indicaciones de posibles defectos.

Las discontinuidades son interrupciones en la estructura de un material. Estas interrupciones pueden aparecer en el metal base, en el material de aporte que forma el cordón de soldadura o en la llamada zona afectada térmicamente. Las discontinuidades que no satisfacen la exigencias de los códigos o especificaciones utilizadas en la inspección son consideradas como defectos.

A continuación, en las siguientes subapartados, se enumeran los defectos habituales en todos los tipos de soldaduras. Se incluye una breve descripción de las características más significativas de la indicación producida en la imagen radiográfica, aportando las probables causas que explican la aparición del defecto y que tienen lugar durante el proceso de soldadura. Este repaso lo haremos distinguiendo entre discontinuidades internas y por tanto solamente detectables radiográficamente y discontinuidades superficiales apreciables mediante inspección visual. Asimismo, al final del capítulo se ilustran algunos ejemplos de imágenes radiográficas de uniones soldadas obtenidas mediante digitalización de los patrones del IIW, mostrando indicaciones de los tipos de defectos más importantes para el proceso de inspección radiográfica.

### 1.3.1 Discontinuidades Internas

#### Mordeduras Internas

**Apariencia radiográfica.** Está caracterizada por una línea oscura irregular, tal como se ilustra en la figura 1.8.

**Causa:** Las mordeduras internas o de raíz son erosiones del metal base cercano a la raíz del cordón de soldadura. Se ocasionan en las mismas circunstancias en que se dan las mordeduras externas, que se describen en un apartado posterior.

#### Inclusiones de Escorias

**Apariencia radiográfica.** Se caracterizan por manchas oscuras con aristas formando ángulos irregulares y formas diversas, localizadas en posiciones aleatorias dentro del cordón de soldadura. Pueden aparecer encadenadas siguiendo líneas paralelas al eje del cordón. En la figura 1.9 se muestra un claro ejemplo de estas inclusiones de escoria.

**Causa:** Las inclusiones de escorias se producen cuando residuos de escorias se quedan aprisionados en el metal fundido por causa de: una falta de limpieza de los cordones en soldaduras en varias pasadas, por la elección inadecuada de un electrodo, por la inclinación incorrecta del electrodo o por baja intensidad de corriente en el electrodo.

#### Inclusiones de Tungsteno

**Apariencia radiográfica.** Viene condicionada por la menor densidad del tungsteno que el aluminio o acero del metal base; por tanto se muestra como un

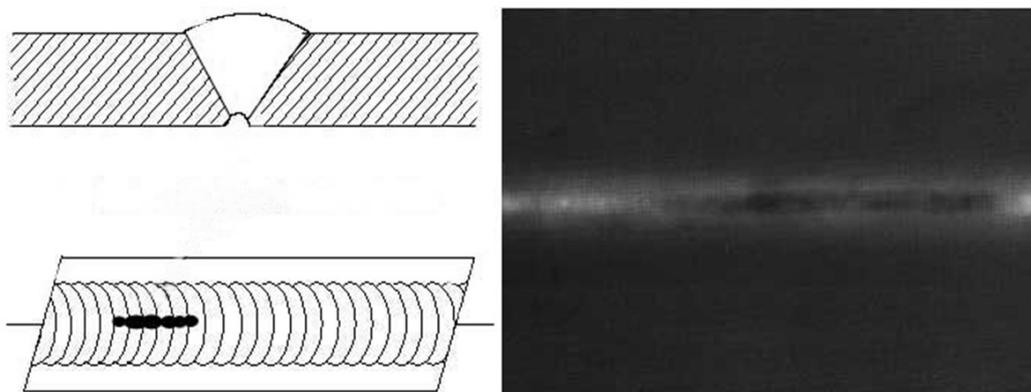


Figura 1.8: Mordeduras internas o de raíz.

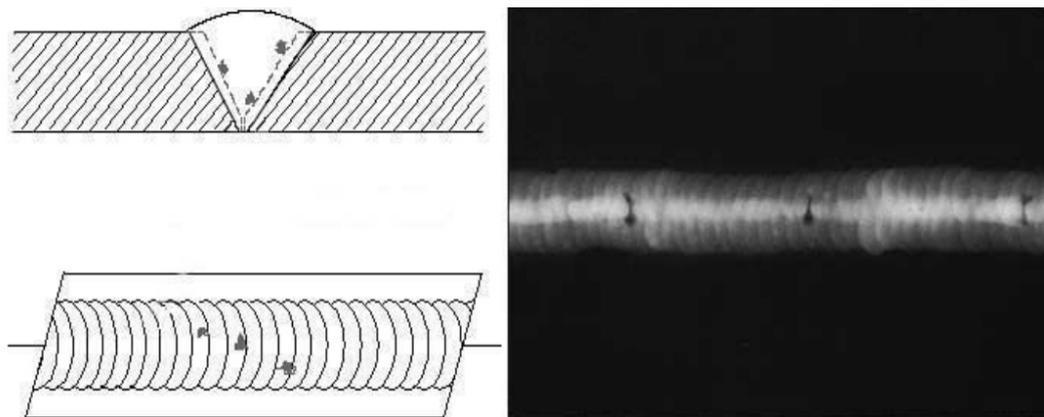


Figura 1.9: Inclusiones de escorias.

área de mayor luminosidad (blanca) con los bordes afilados que se distingue claramente en la radiografía, tal como pone de manifiesto la figura 1.10.

**Causa:** El Tungsteno es un denso y quebradizo material utilizado en los electrodos en soldaduras con arco protegido con gases inertes de tungsteno. Si se utiliza un procedimiento de soldeo inapropiado, el tungsteno puede quedar atrapado en el cordón.

### Porosidades Aisladas

**Apariencia radiográfica.** Por tener los gases menor densidad que el metal, se dejan atravesar más fácilmente por la radiación, formando unas impresiones oscuras redondeadas caracterizadas por manchas irregulares con variaciones de densidad que se presentan aisladas, salteadas y/o agrupadas formando rosarios. En la figura 1.11 se señalan estas porosidades mediante unas flechas para una mejor localización.

**Causa:** Los poros son cavidades esféricas u ovaladas formadas al quedar atrapados gases durante la fase de solidificación en el proceso de soldeo. El origen se puede atribuir a distintas causas: elevado contenido en C, S, P ó presencia de óxidos en el metal base por falta de limpieza en la junta, excesiva intensidad de corriente, lo que provoca un calentamiento excesivo del electrodo y el despegue del revestimiento, o a una excesiva longitud el arco en la operación de soldeo.

### Porosidades Agrupadas

**Apariencia radiográfica.** Cuando un grupo de burbujas de gas queda confinado en una pequeña área del cordón aparecen las porosidades agrupadas que se manifiestan con una imagen radiográfica muy similar a la de los poros aislados,

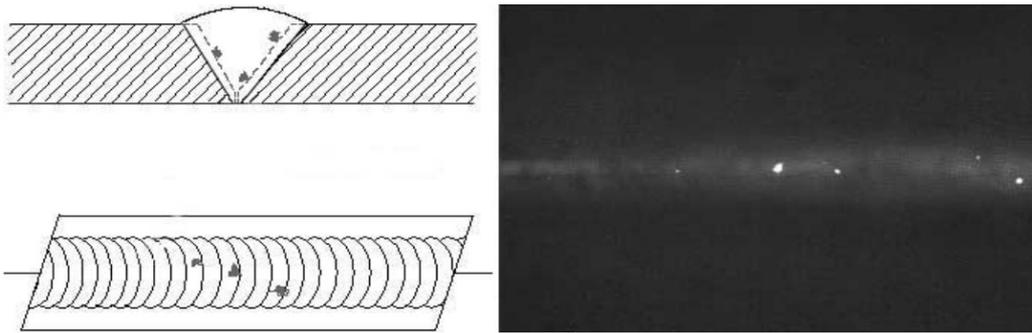


Figura 1.10: Inclusiones de Tungsteno.

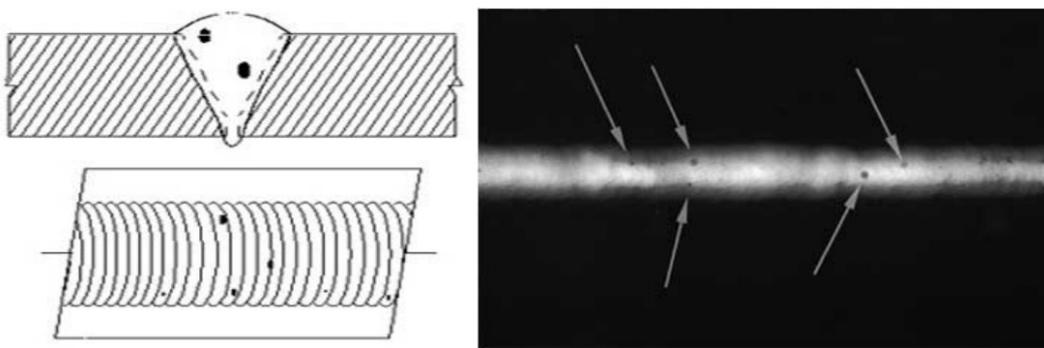


Figura 1.11: Poros aislados.

pero las indicaciones aparecen formando agrupamientos, como las pososidades de la figura 1.12.

**Causa:** La causa es la contaminación por humedad de la capa de flux de los electrodos. La humedad se convierte en gas al calentarse y queda atrapada en el cordón durante el proceso de soldadura.

### Grietas

**Apariencia radiográfica.** Se caracterizan por líneas oscuras con bordes ásperos que pueden extenderse en direcciones paralelas al eje del cordón (grietas longitudinales) o perpendiculares al mismo eje (grietas transversales). Algunas veces pueden aparecer como cola en una inclusión o en un poro. La figura 1.13 muestra algunos de estos defectos.

**Causa:** Las grietas son discontinuidades en el cordón de soldadura originadas cuando el metal está completamente solidificado (grietas de tensión) o con el metal aún en estado plástico (grietas de contracción). Su aparición puede estar originada por distintas circunstancias: por una excesiva rigidez de la pieza (se da

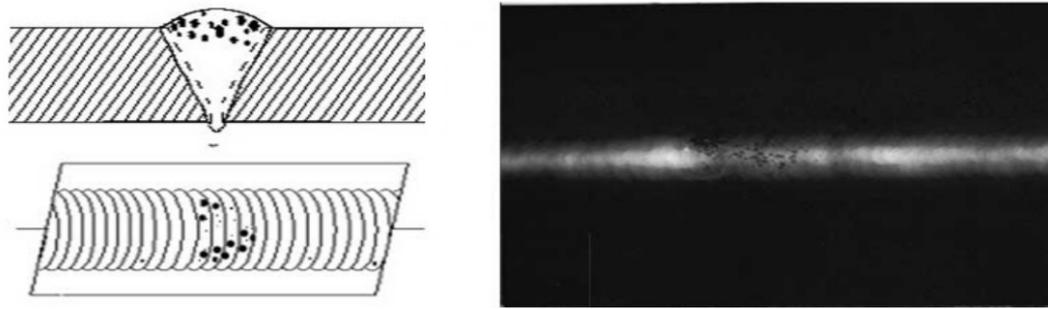


Figura 1.12: Poros agrupados.

en aceros con excesivo contenido en C, Mn, S, P), por una elección del material de aportación inapropiada para el metal base que se está soldando, o por un enfriamiento demasiado rápido del metal depositado debido a un insuficiente precalentamiento de la pieza o a causas externas al proceso de soldadura.

### Falta de Penetración

**Apariencia radiográfica.** La falta de penetración aparece en la imagen radiográfica como una zona oscura bien definida, de bordes irregulares que siguen la zona de la cara inferior de la raíz centrada en el eje del cordón como se pone de manifiesto en la figura 1.14.

**Causa:** La falta de penetración o penetración incompleta ocurre cuando el metal de aportación es incapaz de penetrar hasta la raíz de la junta, ocasionado generalmente por un mal diseño de la junta o mala práctica en la operación de soldeo. Esta discontinuidad origina un foco de concentración de tensiones que facilita la aparición y propagación de grietas.

### Falta de Fusión entre capas

**Apariencia radiográfica.** Aparecen en la imagen como débiles líneas oscuras con los bordes claramente definidos, tal como muestra la figura 1.15.

**Causa:** Esta ocurre cuando el metal de aportación no se fusiona adecuadamente con el metal base. El arco no funde suficientemente el metal base y origina un charco ligeramente líquido que fluye en el interior del metal base sin fijación.

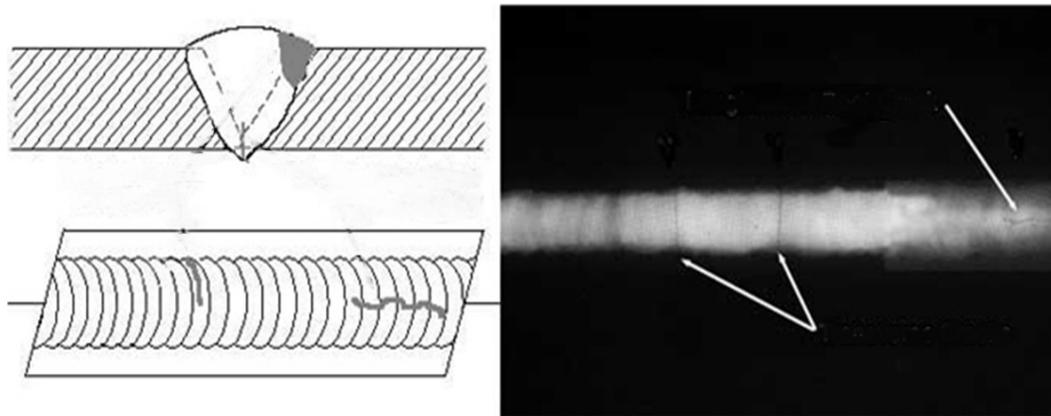


Figura 1.13: Grietas transversales y longitudinales.

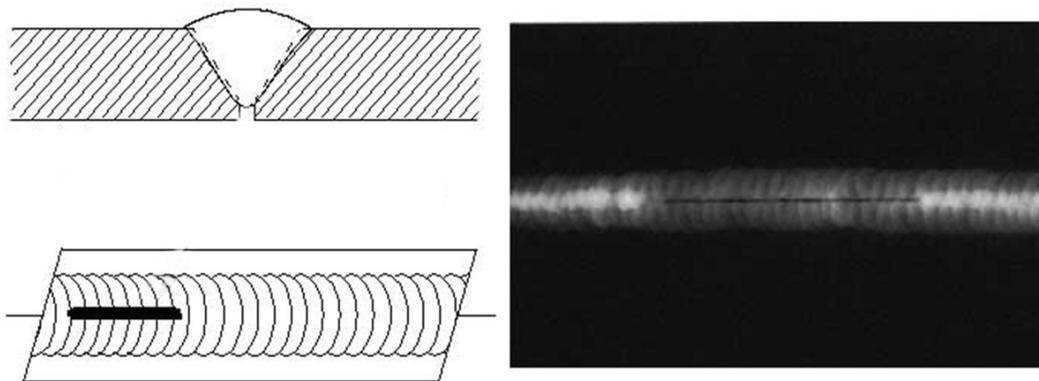


Figura 1.14: Falta de penetración.

### Fusión Incompleta

**Apariencia radiográfica.** Su imagen radiográfica aparece como una línea o banda recta y oscura, dependiendo de la orientación de la fuente. La figura 1.16 es un claro ejemplo de fusión incompleta.

**Causa:** Se trata de una falta de unión entre el metal de aportación y las paredes del metal base en la junta de la soldadura.

### 1.3.2 Discontinuidades Externas

#### Mordeduras Externas

**Apariencia radiográfica.** Está caracterizada por una o dos bandas oscuras, generalmente localizadas en ambos lados de los bordes del cordón de soldadura y con forma geométrica aleatoria, tal como muestra la figura 1.17.

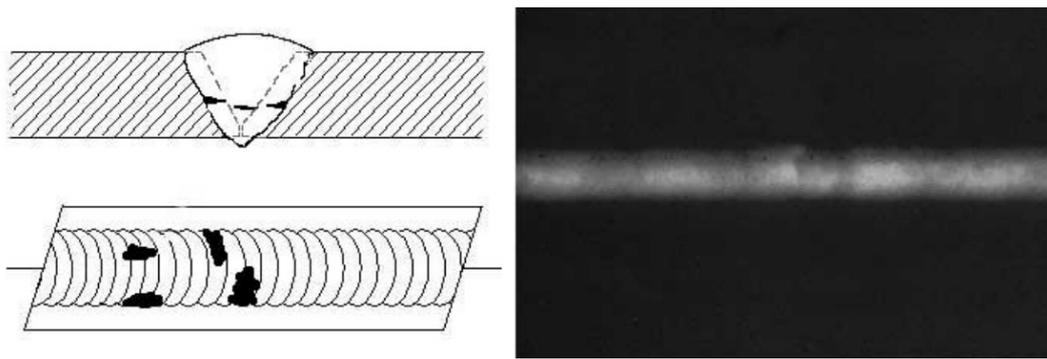


Figura 1.15: Falta de fusión entre capas.

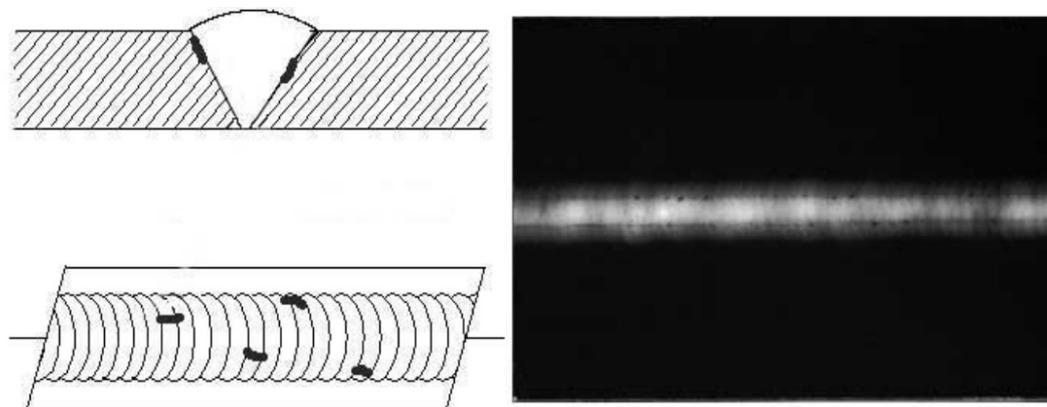


Figura 1.16: Fusión incompleta.

**Causa:** Las mordeduras externas o de corona representan falta de material en los bordes del cordón. Se producen por fusión, quemado y pérdida de material. Se atribuyen, bien a una excesiva intensidad de corriente al soldar a una inclinación inadecuada del electrodo, o a la premiosidad excesiva del soldador en los movimientos del electrodo o soplete ocasionando un exceso de velocidad en el proceso de soldeo. Esto hace que muchas veces aparezcan en la radiografía de forma periódica.

### Inclusiones de Óxido

**Apariencia radiográfica.** Las inclusiones de óxido se identifican como una discontinuidad oscura de forma irregular, debida a la menor densidad de éstas con relación al metal base. Son generalmente apreciables sobre la superficie del cordón de soldadura mediante una simple inspección visual como se puede apreciar en la figura 1.18.

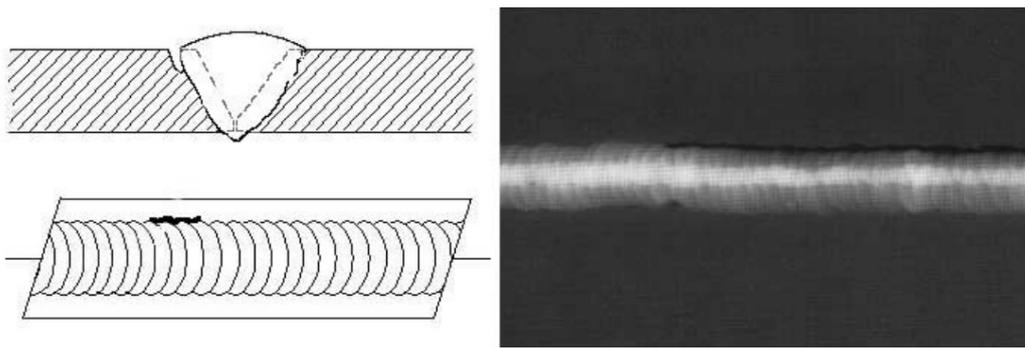


Figura 1.17: Mordeduras externas o de corona.

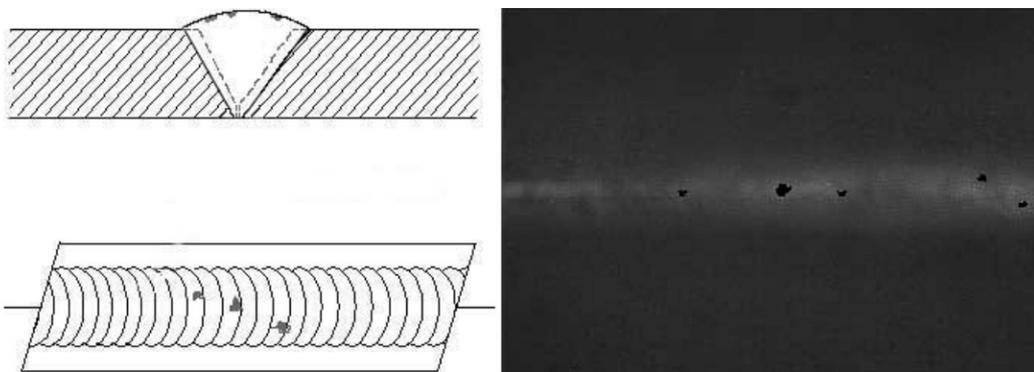


Figura 1.18: Inclusiones de óxido.

### Rechupe o Concavidad Interna

**Apariencia radiográfica.** El aspecto es muy similar a una falta de penetración pero la línea tiene los bordes irregulares, a menudo bastante ancha y situada en el centro del cordón, tal como puede verse en la figura 1.19.

**Causa:** Ocurre cuando el metal de aportación se contrae al enfriarse, cesando la contracción en el interior de la raíz.

### Desalineamiento

**Apariencia radiográfica.** La imagen radiográfica muestra una diferencia perceptible de la densidad de las dos piezas que forman la unión, motivada por la diferencia en los espesores. El desalineamiento puede llevar asociado una indicación en forma de línea recta oscura causada por el borde saliente de una de las piezas como se ilustra en la figura 1.20.

**Causa:** Ocurre cuando dos piezas que van a ser soldadas juntas no son alineadas correctamente.

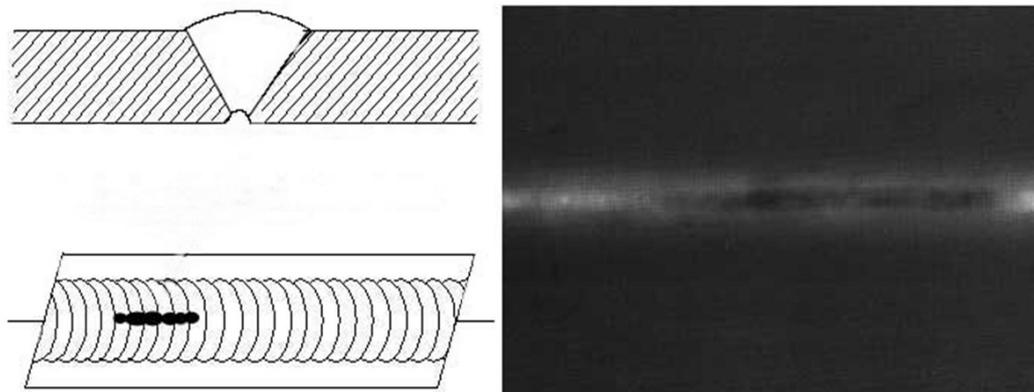


Figura 1.19: Rechupe o concavidad interna.

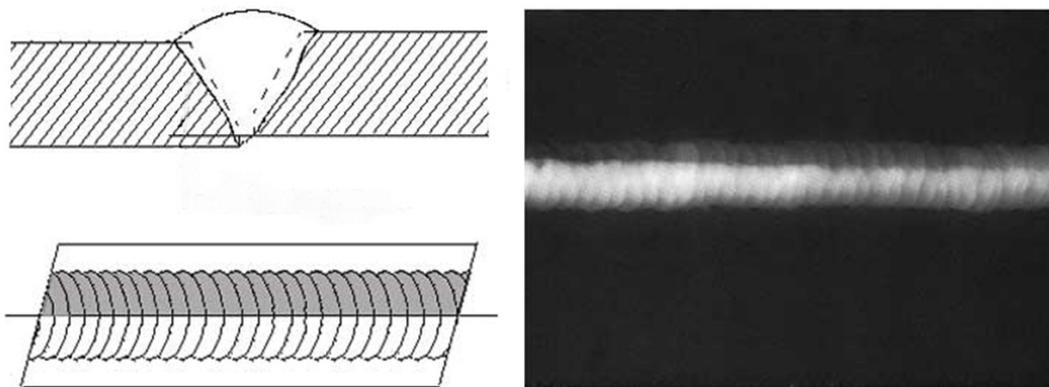


Figura 1.20: Unión soldada desalineada.

### Reforzamiento Insuficiente

**Apariencia radiográfica.** La imagen radiográfica nos evidencia si la soldadura tiene un reforzamiento inadecuado, porque la densidad de la imagen en esa área será mucho mayor (más oscura) que la densidad de la imagen en los alrededores del metal base, tal como puede apreciarse en la figura 1.21.

**Causa:** Sucede de forma continua o intermitente cuando a lo largo del cordón de soldadura el espesor del metal de aportación depositado es menor que el espesor del metal base.

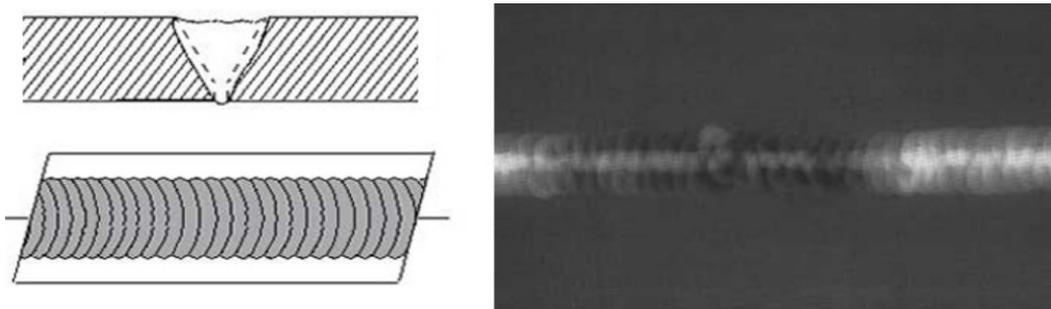


Figura 1.21: Insuficiente reforzamiento.

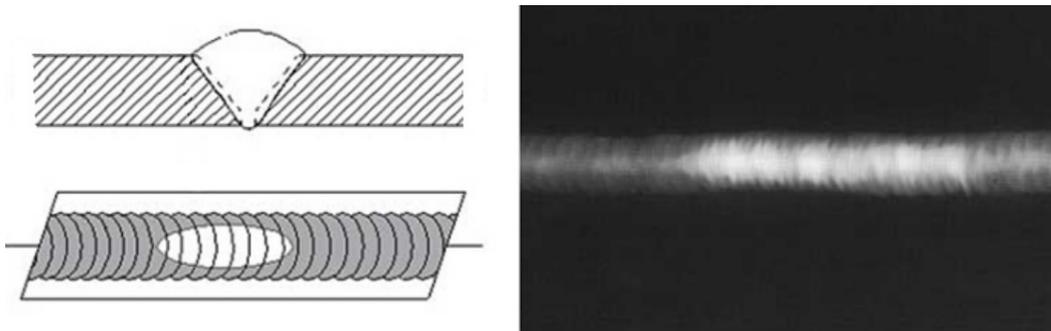


Figura 1.22: Excesivo reforzamiento.

### Reforzamiento Excesivo

**Apariencia radiográfica.** En la imagen radiográfica un exceso de refuerzo aparece como una zona más luminosa localizada en el cordón de soldadura, como el de la figura 1.22.

**Causa:** Es una zona del cordón de soldadura en donde se ha depositado en exceso material de aportación.

### 1.3.3 Ejemplos de Defectos

A modo de ejemplo, y para ilustrar la diversidad de defectos que pueden detectarse en las imágenes radiográficas de uniones soldadas, en las figuras 1.23 a 1.28 se presentan una serie de radiografías escaneadas de la colección del IIW/IIS, conteniendo indicaciones de algunos de los defectos descritos anteriormente y que se han utilizado en este trabajo como conjunto de prueba, entrenamiento y validación del sistema automático de inspección de este tipo de imágenes. En ellas se puede apreciar la gran variedad en los valores de los tres parámetros que definen la calidad de las imágenes (contraste, definición y densidad radiográfica) así como la importante presencia de objetos en la región al margen del cordón de soldadura, que constituye la zona de interés de nuestro análisis.

### 1.4 Sumario

En este capítulo hemos realizado una descripción teórica de los tres parámetros que intervienen en la definición de la calidad de una imagen radiográfica en relación con la capacidad de mostrar los detalles o discontinuidades presentes: contraste, definición y densidad radiográfica. A continuación, se han mostrado los procedimientos y dispositivos internacionalmente aceptados como indicadores de calidad por la mayoría de los códigos y normas de aplicación en el control de calidad de uniones soldadas. Por último, y tras realizar una explicación de los distintos objetos que componen la imagen de una unión soldada, se ha incluido una breve definición de los defectos habituales en todos los tipos de soldaduras, aportando las características más significativas de la indicación producida en la radiografía y refiriendo las probables causas que explican la aparición del defecto.

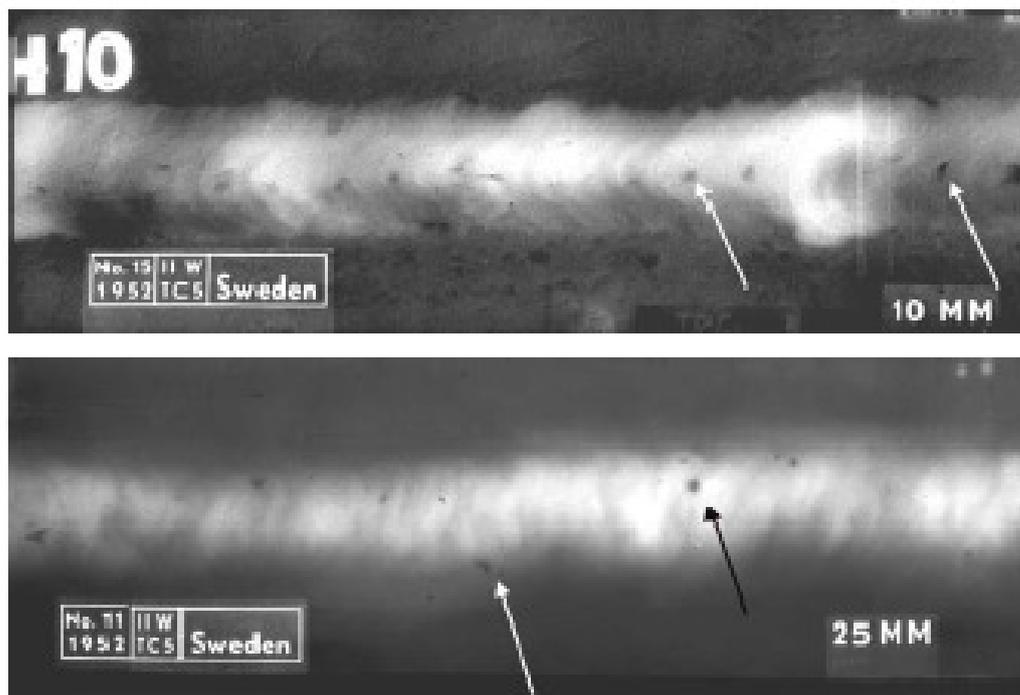


Figura 1.23: Imágenes radiográficas con inclusiones de escoria aisladas.

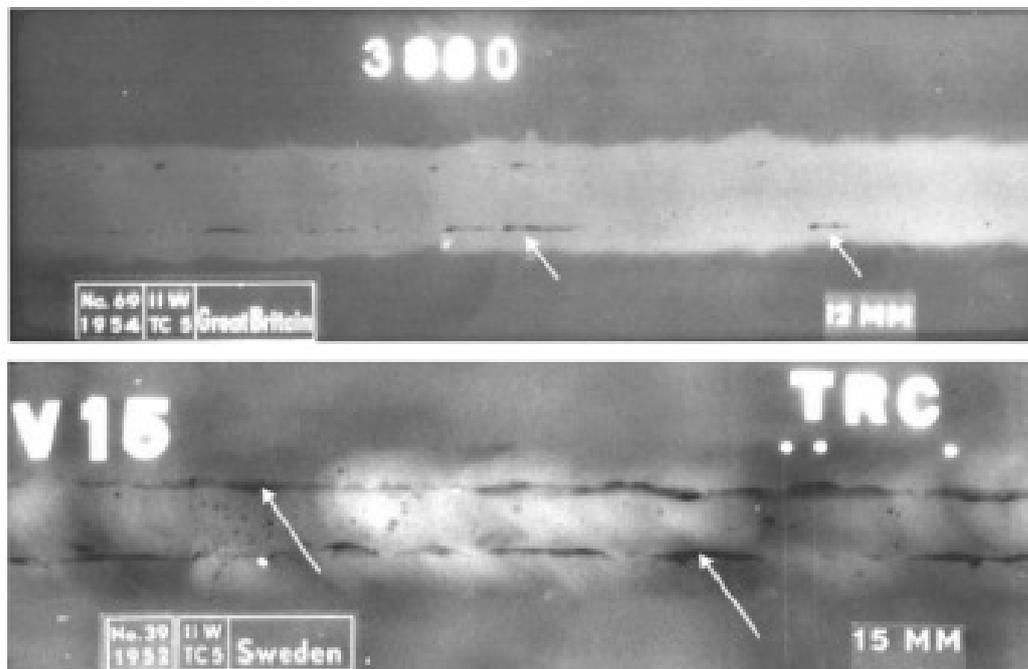


Figura 1.24: Imágenes radiográficas con inclusiones de escoria alineadas.

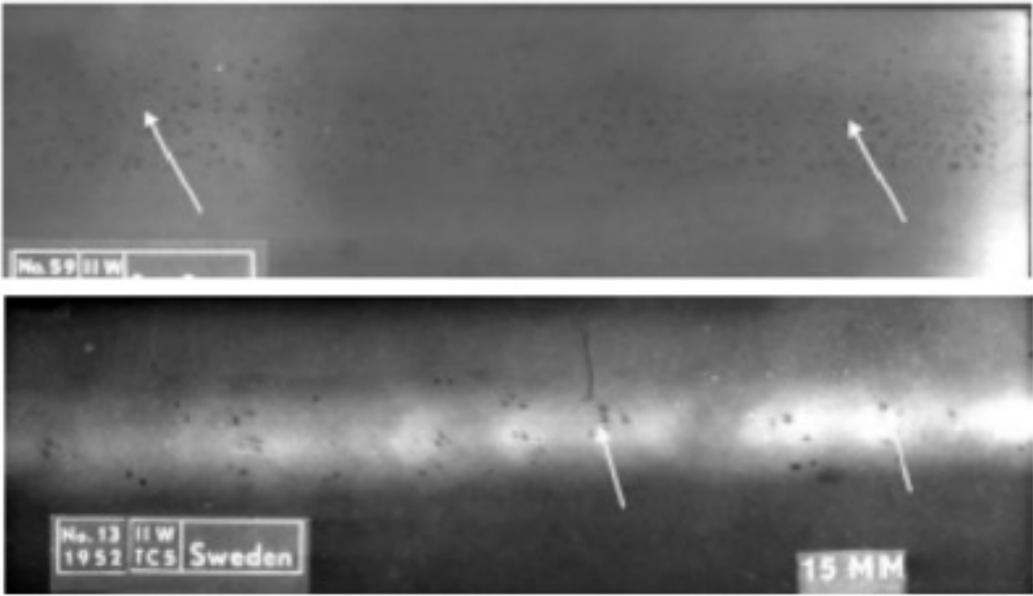


Figura 1.25: Imágenes radiográficas conteniendo poros.

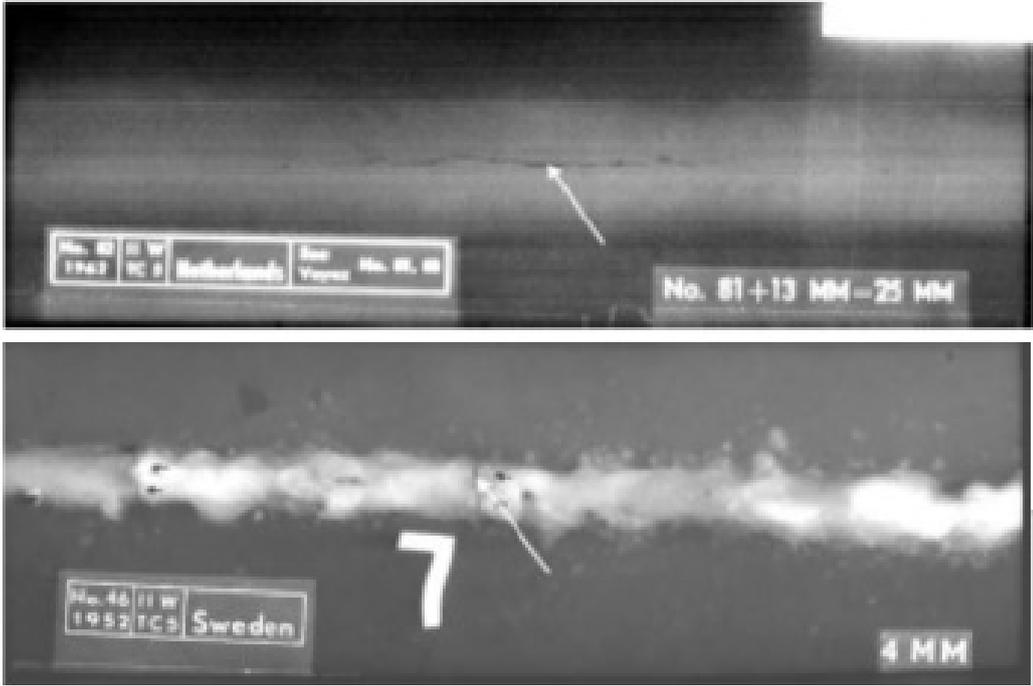


Figura 1.26: Imágenes radiográficas conteniendo grietas.

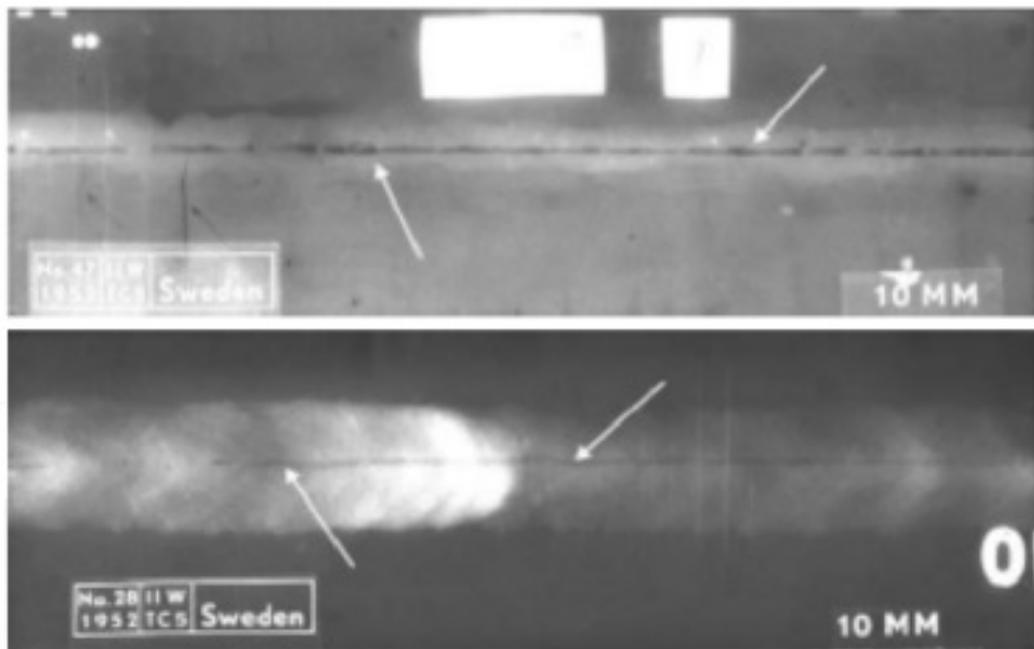


Figura 1.27: Imágenes radiográficas conteniendo falta de penetración.

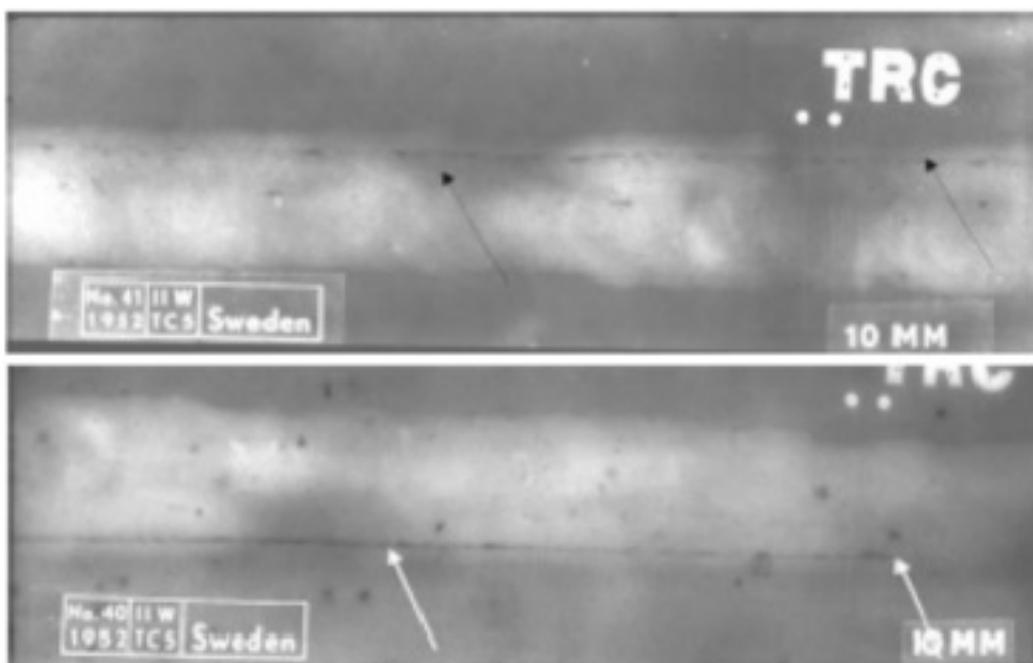


Figura 1.28: Imágenes radiográficas conteniendo falta de fusión.



# Capítulo Dos

---

## Sistemas Automáticos de Inspección de Imágenes Radiográficas de Uniones Soldadas. Revisión Bibliográfica

---

Durante los últimos 30 años, debido a la complejidad del problema de la detección de defectos en soldaduras, se ha desarrollado una cantidad considerable de trabajo de investigación tendente a conseguir sistemas automáticos (o semiautomáticos) de inspección de radiografías de uniones soldadas. A continuación presentamos un resumen del *estado del arte*, basándonos en las publicaciones que han aparecido en las dos últimas décadas, comparando las distintas técnicas que se han utilizado para cada una de las etapas y apuntando las posibles tendencias en el progreso de las investigaciones para los próximos años.

### 2.1 Adquisición de las Imágenes

Las técnicas convencionales de inspección radiográfica comportan la realización de un nuevo análisis visual de películas radiográficas mediante negatoscopio. Dada la subjetividad inherente a esta forma de proceder, existen diversos factores que influyen en la aceptabilidad de los resultados obtenidos en los ensayos: calidad de la imagen (influenciada por diversos parámetros relacionados con la técnica de inspección), buen funcionamiento del negatoscopio, agudeza visual del inspector, o su experiencia en interpretación de radiografías [29] y [30].

Durante muchos años, el método convencional de inspección ha sido el único utilizado. Con la progresiva introducción del uso de computadores para la interpretación de las imágenes radiográficas se ha impuesto la necesidad de realizar un proceso de digitalización de las imágenes registradas sobre placas radiográficas.

El proceso de digitalización de una señal o imagen analógica consta de dos etapas secuenciales: muestreo y cuantificación. El muestreo consiste en proceso mediante el cual la imagen es convertida en una matriz discreta de  $m \times n$  píxeles, lo que determina la resolución espacial de la imagen digital. La segunda operación es la cuantificación de los píxeles, que consiste en asignar un valor binario de entre un conjunto en cada píxel. Los niveles de cuantificación suelen ser potencias de 2 para facilitar su almacenamiento en el computador, y el número de niveles posibles define la resolución radiométrica. Cuando las imágenes sólo tienen información lumínica se habla de una imagen en niveles de grises, siendo la cuantificación del píxel de tipo escalar. En general, se suele emplear un byte de cuantificación por píxel, consiguiendo 256 niveles de grises; el cero será el color negro y el valor 255 corresponderá con

el blanco, mientras que entre el cero y este valor máximo se distribuirán los diversos tonos de grises. Las referencias [12] y [33] contienen descripciones detalladas de los procesos de digitalización.

Las películas radiográficas pueden digitalizarse mediante diversos métodos. Las imágenes pueden registrarse directamente en formato digital mediante sistemas de radiografiado digital o pueden obtenerse mediante un proceso separado de digitalización de las películas radiográficas. Los sistemas de radiografiado digital utilizados en NDT son: la radiografía computerizada y la radiografía digital directa. En los primeros, una placa de fósforo fotosensible expuesta a la acción de un rayo láser produce una imagen digital, mientras que en los segundos la digitalización se consigue mediante una radiación de fotones que al atravesar el objeto produce la imagen que inmediatamente puede mostrarse en un monitor. La mayor resolución de este segundo método tiene como contrapartida la fragilidad de los soportes utilizados, lo que limita su uso a aplicaciones en laboratorio.

Si nos centramos en los procedimientos de digitalización de películas, los dispositivos CCD (*Charge-Coupled Device*) son los más utilizados para digitalizar este tipo de imágenes sobre placa, lo que se puede conseguir colocándolas en un negatoscopio y fotografiándolas con una cámara de esta tecnología. En este proceso, la energía de los fotones capturados por la cámara se convierte para cada píxel de la imagen en voltaje, de forma que el número de píxeles se determina con la resolución espacial. Suga et al. [93] describe el procedimiento para obtener imágenes de alto contraste durante la digitalización utilizando una cámara CCD. Shafeek en [88] y [89] ha utilizado en sus trabajos recientemente publicados el método de Suga et al. con buenos resultados.

Actualmente existen varios tipos de escáneres comerciales adecuados para digitalizar radiografías, que operan con la modalidad de transmisión de luz. En este caso la película se sitúa en la zona de digitalización que puede ser del tipo *flat-bed* (parecido a los escáner convencionales), y la luz llega del adaptador transparente y atraviesa la imagen; esta luz es generalmente captada por un dispositivo CCD en la parte trasera del escáner. La resolución y densidades límites de los aparatos pueden llegar a digitalizar películas con densidades ópticas superiores a 4.0. Existen también escáneres que utilizan rayos láser como fuentes de luz, que permiten una concentración mucho mayor de fotones, y por lo tanto mayor precisión para digitalizar películas de alta densidad.

En trabajos como los de Cherfa et al. [14], Li y Liao [48] y Silva [20], se utiliza un escáner para digitalizar las radiografías, llegando a resoluciones espaciales de 70  $\mu\text{m}$ . La mejora en la calidad de las imágenes obtenidas con este procedimiento, si la comparamos con las obtenidas con negatoscopio-cámara CCD, es evidente.

Por último, indicar que una presentación exhaustiva de los diferentes procedimientos de digitalización de películas para ensayos no-destructivos la podemos encontrar en [110] y [111], habiéndose de regir todos ellos por la norma ASME V [6].

## 2.2 Preprocesado de las Imágenes

La calidad de las imágenes radiográficas es un factor importante en la detección de los defectos. Ésta se evalúa generalmente mediante el uso de los indicadores de calidad (IQI) [12]. Factores tales como el tipo de película, densidad de la película, distancia focal, nivel de energía de la fuente y tiempo de exposición afectan de manera decisiva a la viabilidad de una correcta detección y clasificación posterior de defectos. Incluso cuando la elección de los parámetros han sido realizada de manera cuidadosa, las imágenes pueden presentar problemas tales como la existencia de ruido, iluminación no uniforme y deficiente contraste, de manera que, cuando existe un pequeño defecto en el cordón de soldadura, puede confundirse con el ruido de la imagen originado en la etapa de digitalización o incluso en el proceso de inspección [64].

La etapa de procesamiento de radiografías industriales es bastante compleja, y la diversidad de técnicas utilizadas se puede constatar en numerosos trabajos.

La primera fase en procesamiento de imágenes es la atenuación del ruido que puede tener su origen o en la técnica de ensayo o en el proceso de digitalización, este último conocido como ruido electrónico. En esta fase generalmente se aplican filtros pasa-bajo puesto que el ruido se caracteriza por frecuencias altas [12] y [33], de entre los cuales el más frecuentemente utilizado es el filtro *mediana*. Este filtro da un buen rendimiento en la eliminación de ruido sin remover defectos y sin disminuir la definición de la imagen [3], [4], [33] y [62]. Cherfa [14] relata la posibilidad de la utilización de filtros pasa-baja del tipo Gaussiano, exponencial y mediana, recalando la idoneidad del filtro mediana por las ventajas antes citadas. Wang [102] resalta la dificultad para atenuar el ruido existente en radiografías, debido a que la variación de niveles de gris en las imágenes hace muy difícil la elección de un filtro o una técnica de atenuación que pueda utilizarse en todas las imágenes radiográficas. Sin embargo, afirma que el filtro mediana con ventanas de (3x3) y (5x5) es el más adecuado.

Por otro lado, normalmente las imágenes radiográficas tienen un contraste deficiente debido a problemas como: la radiación no uniforme ocasionada por la técnica de inspección utilizada, variación en los espesores de las piezas inspeccionadas, inadecuado tiempo de exposición e inadecuado manejo en el revelado de la película [12]. El proceso de digitalización de radiografías puede ser también responsable del bajo contraste de la imagen digital, principalmente en sistemas que no tienen un buen nivel dinámico de grises. Problemas como desenfoque, reflexión y distorsión deben ser controlados de forma efectiva [33].

El objetivo de la etapa de mejora del contraste en radiografías es realzar las regiones en las que existen defectos, aumentando el rango dinámico de sus niveles de gris sin afectar las otras regiones de la imagen; de ese modo garantizamos el éxito de las técnicas de segmentación. [44]. Para optimizar el contraste es frecuente utilizar una etapa conocida como *extensión* del contraste, que persigue la optimización de la distribución de los niveles de gris de la imagen. Para extender el contraste de la imagen radiográfica, Cherfa et al. [14] utilizan una función de transformación aplicada al histograma de los niveles de grises, función también utilizada por Merenyi y Heller [65] para optimizar la distribución de los niveles de grises en las radiografías con las que ellos trabajan. El resultado de este procedimiento puede considerarse

satisfactorio, mejorando considerablemente la calidad de las imágenes radiográficas en términos de su contraste.

Recientemente, Shafeek et al. [88] y [89] han aplicado las técnicas de extensión del contraste y de la ecualización del histograma sólo al cordón de soldadura para facilitar la siguiente etapa de segmentación. Cuando la extensión y/o ecualización del histograma de la imagen se aplica sólo a la región en la que se sospecha la existencia de defectos, entonces todos los niveles de gris no uniformes existentes en la radiografía son eliminados, lo que permite en muchas ocasiones la segmentación con sólo la aplicación de un simple umbral en esta región.

Finalmente, Nacereddine et al. [75] desarrollan dos técnicas de mejora del contraste basadas en dos enfoques distintos. Por un lado los píxeles son modificados mediante una función de transformación basada en la distribución de niveles de gris de la imagen completa (enfoque global), y por otro lado las modificaciones de los niveles de gris de los píxeles se realizan en base a las propiedades estadísticas de los vecinos de cada píxel de la imagen (enfoque local). En este caso se aplicó una extensión dinámica del contraste mediante la transformación de la LUT (*Look Up Table*) como se observa en la figura 2.1, como método global de realzado, y para la mejora local del contraste un método que transforma la imagen de entrada  $f(x, y)$  en una nueva imagen  $g(x, y)$  utilizando la siguiente expresión:

$$g(x, y) = A(x, y)[f(x, y) - \mu(x, y)] + \mu(x, y) \quad (2.1)$$

donde  $A(x, y) = k \frac{M}{\sigma(x, y)}$  para  $0 < k < 1$ ,  $\mu(x, y)$  y  $\sigma(x, y)$  son respectivamente el nivel de gris medio y la desviación estándar de la vecindad definida en el píxel considerado,  $M$  es la media global de la imagen de entrada y  $k$  es un valor constante.

### 2.3 Segmentación del Cordón de Soldadura

En general, revisando el estado del arte de este tipo de sistemas, se echan a faltar trabajos publicados sobre la segmentación de los cordones de soldadura en las aplicaciones de inspección automática de radiografías. Presentamos a continuación los que a nuestro juicio representan aportaciones más relevantes en esta etapa

Koshimizu y Yoshida [35] describen una propuesta pionera basada en una simple detección de bordes del área esperada del cordón de soldadura. Para muchos casos esto resulta inviable, ya que es probable que durante el procedimiento de inspección la pieza cambie de orientación y posición. Además, si las piezas a soldar tienen una geometría compleja la simple detección de bordes de los límites del cordón resulta insuficiente. A estas circunstancias se pueden sumar problemas adicionales si la imagen de la soldadura contiene una cantidad significativa de ruido o si la transición entre el cordón y el metal base es algo difusa. Por estas razones Lawson y Parker [47] introdujeron modificaciones en la técnica, recurriendo al reconocimiento adaptativo del cordón de soldadura basado en una red neuronal artificial multicapa (ANN). La red es entrenada con una imagen que muestra una típica soldadura que va a ser inspeccionada, junto a una plantilla con un esquema muy simple del cordón.

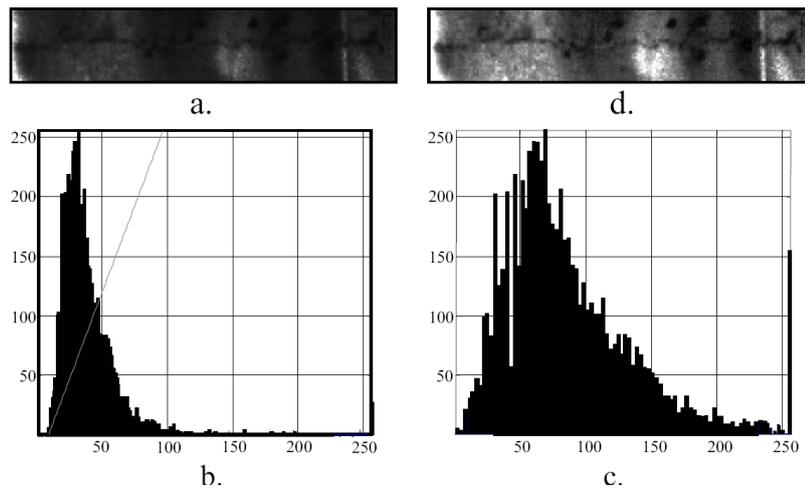


Figura 2.1: Mejora de contraste mediante extensión dinámica. (a) región de interés; (b) histograma de a. y función LUT; (c) histograma extendido; (d) imagen mejorada. (Nacereddine et al. [75])

Li y Liao [49] extraen el cordón de soldadura de la imagen radiográfica por medio del análisis de tres características de los cordones: ancho, error medio cuadrático entre los perfiles de los defectos y la curva Gaussiana, y los picos de intensidad de los objetos. De acuerdo con esto, un perfil de intensidad del cordón se comporta como una distribución Gaussiana en mayor medida que otros objetos presentes en la imagen. Para verificar la capacidad de discriminación de estas clases (soldadura o no soldadura), emplean el criterio de distancia entre los valores medios de las características de cada clase, así como el solapamiento entre las clases. Para el criterio de distancia el concluyen que la característica anchura de los objetos es la más adecuada, y para el criterio del solapamiento el error medio cuadrático se muestra como el de más rendimiento. Utilizando estas dos características, han empleado un total de 44 datos en un clasificador de lógica borrosa tipo K-NN para identificar las zonas de cordón o no cordón, alcanzando un 93.2 % de rendimiento.

Liao y Ni [56] proponen una metodología para la extracción de cordones de soldadura de imágenes radiográficas digitalizadas usando el software *Khoros*. El método se basa de nuevo en la observación de que las intensidades de los píxeles en el cordón siguen una distribución más Gaussiana que en otras áreas de la imagen. La metodología de extracción consta de varias etapas. En primer lugar se divide la imagen en cuatro partes aproximadamente iguales, y seguidamente se extraen tres perfiles correspondientes a tres posiciones distintas distanciadas 100 y 200 píxeles respectivamente, en los que se aplican un algoritmo de detección de picos y de los correspondientes valles asociados a cada uno de los objetos detectados como se muestra en la figura 2.2. Finalmente se evalúa la similitud entre la curva de cada objeto y su Gaussiana en términos de error cuadrático medio (MSE) y se identifica el cordón de soldadura como el de menor valor. Los resultados obtenidos muestran la efectividad total de la metodología (100 % de éxito) para la extracción de cordones con bordes lineales, pero en el trabajo se subraya la necesidad de introducir mejoras

en el método para los casos de cordones con bordes redondeados.

Liao y Tang [57] han aplicado un procedimiento basado en una red neuronal perceptrón multicapa (MLP) para extraer el cordón de soldadura. Para ello definen un conjunto de características capaces de discriminar un cordón del resto de la imagen, extraídas del perfil transversal de la imagen del cordón: posición y ancho del pico, error cuadrático medio entre el perfil del cordón y una curva Gaussiana e intensidad del pico. El sistema primero aplica un algoritmo para detectar picos y objetos en la imagen basado en la detección de cambios en la tangente del perfil en cada punto. Para cada objeto detectado, se determina la intensidad y la posición de los picos, y después se mide su ancho y se calcula el error cuadrático medio. Seguidamente se utiliza una red neuronal tipo perceptrón con dos capas para distinguir las zonas de cordón y no cordón, utilizando la técnica de Fletcher-Reeves para entrenar la red que ofrece mejores resultados que el método *backpropagation*. El resultado es una imagen binaria con el cordón en blanco y el fondo en negro. Para eliminar el ruido y los errores en la clasificación y restaurar la continuidad del cordón de soldadura optimizando los resultados, se aplica un sistema de post-procesamiento. Dentro de este trabajo se desarrollan una serie de pruebas para conseguir la mejor configuración posible de la red, concluyendo que la red con siete neuronas en la capa intermedia es la que da mejor rendimiento, alcanzando un 100% de precisión en la clasificación de los cordones.

En otro trabajo, Liao et al. [54] emplean clasificadores borrosos del tipo *fuzzy K-NN* y *fuzzy C-Means*, en lugar de redes neuronales, lo que les permite segmentar cordones tanto rectos como de forma curva. La metodología consta de tres etapas: extracción de características, clasificación de patrones y post-procesamiento. Cada imagen es procesada línea a línea para extraer tres características para cada objeto. Estas características son el ancho, el MSE entre el objeto y su gaussiana y el pico de intensidad (nivel de gris). Los algoritmos *fuzzy K-NN* y *fuzzy C-Means* se utilizan para clasificar cada objeto como cordón de soldadura o falso positivo. La operación de post-procesado se aplica para eliminar el ruido generado y los falsos positivos. En el trabajo se concluye que ambos clasificadores son capaces de extraer de forma adecuada el cordón de soldadura.

En un trabajo más reciente, Liao [52] ha desarrollado un sistema experto basado en razonamiento borroso para el reconocimiento de cordones de soldadura en imágenes radiográficas. Cada objeto en la imagen es identificado y descrito con un vector de características idéntico al trabajo comentado en el párrafo previo, y las reglas borrosas son extraídas de estas características basándose en una modificación del algoritmo *fuzzy C-Means*. En el trabajo el autor realiza un estudio detallado de determinación de los pesos de las reglas y la función de pertenencia que produzcan el mejor rendimiento en términos de ratios falsos positivos y falsos negativos. Finalmente, compara el rendimiento del sistema experto borroso propuesto con el de la red neuronal MLP estudiada en un anterior trabajo [57], concluyendo que un sistema experto basado en razonamiento borroso diseñado adecuadamente consigue mejor rendimiento que una red neuronal MLP.

Por último, otro trabajo interesante es publicado por Felisberto et al. [27]. La metodología que proponen utiliza un algoritmo genético para dirigir la búsqueda de valores de características (posición, ancho, longitud, y ángulo) que definan mejor

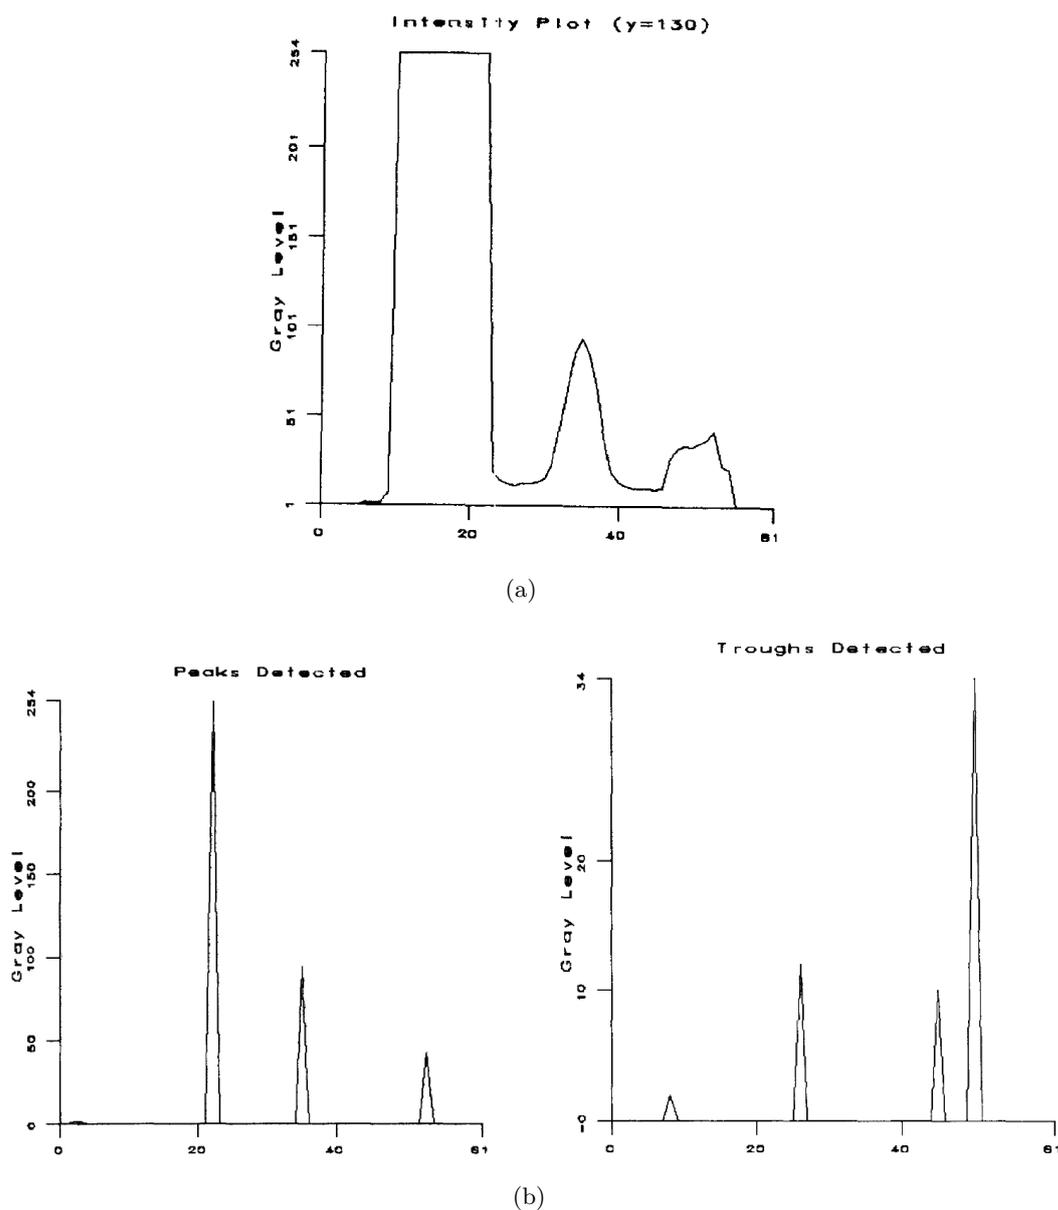


Figura 2.2: (a) Perfil de niveles de imagen radiográfica; (b) Detección de picos y valles de la imagen radiográfica. (Liao y Ni [56])

una ventana en la imagen radiográfica, que encaje con la imagen modelo de un cordón simple de soldadura.

## 2.4 Segmentación de Defectos

Después de aislar el cordón de soldadura del resto de elementos de la imagen radiográfica, necesitamos detectar los candidatos a defectos. La segmentación de los posibles defectos tiene como objetivo la eliminación de la información no relevante,

dejando sólo los objetos de interés de la imagen, en este caso los defectos existentes en el cordón de soldadura. Las técnicas de segmentación más comunes generalmente hacen uso de una serie de filtros que buscan variaciones en los píxeles de la imagen que pueden corresponder a defectos. Algunas de las técnicas están basadas en detectores de bordes (por ejemplo *Canny*, *Deriche*, o *Prewitt* [12], [33]), o también en técnicas conocidas como de crecimiento de regiones [12].

Murakami [71] describe la utilización de técnicas para detectar defectos en radiografías de soldadura utilizando varios tipos de filtros tales como filtros *smoothing*, *bridge*, *Kirsch*, *Prewitt*, y operadores *Sobel*. Da un ejemplo de segmentación radiográfica aplicando una secuencia de estos filtros. Aparentemente el resultado alcanzado es excelente, detectando eficientemente los poros existentes en la imagen. Sin embargo, este método tiene una gran desventaja y es que la secuencia de filtros a utilizar es diferente para cada tipo de imagen radiográfica, lo que hace que el método sea inviable a efectos prácticos.

Carrasco y Mery [8] han desarrollado un método de segmentación basado en filtros de atenuación de ruido, operadores morfológicos, técnicas de detección de bordes tales como el filtro *Canny*, y la transformada de *Watershed*, aplicados según el orden siguiente: primero, se emplea un filtro mediana para reducción del ruido; segundo un filtro *bottom-hat* para separar los posibles defectos del fondo; tercero, las regiones segmentadas son identificadas mediante umbralización binaria; cuarto, se utilizan filtros morfológicos para eliminar la sobre-segmentación; y quinto, se utiliza la transformada *Watershed* para separar las regiones interiores. Como resultado del estudio se obtiene un área bajo la curva de medida de la sensibilidad frente a falsos positivos, o curva ROC (*Receiver Operating Characteristics*), de 0.9358 a partir de un conjunto de 10 imágenes.

Existen ciertos problemas, no obstante, que se presentan al utilizar transformadas de *Watershed*, como son: pobre detección de estructuras delgadas, áreas con bajo contraste en los bordes, sensibilidad al ruido y sobre-segmentación. Alaknanda et al. [2] los solventan desarrollando e implementando una transformada *Watershed* multi-etapa. En una primera etapa aplican la transformada a la imagen radiográfica y el resultado es aún más umbralizado mediante el método Otsu, que binariza la imagen. Después aplican transformaciones morfológicas para separar parcialmente los objetos solapados, a las que sigue la segunda etapa de segmentación *Watershed* para obtener una definición de bordes mejorada. Un esquema del proceso de segmentación se muestra en la figura 2.3.

Otra línea de investigación es la de conseguir la detección de los defectos mediante el estudio del perfil de intensidad de los niveles de grises transversal al cordón de soldadura. Liao y Li [55] han observado que los perfiles de intensidad de los niveles de gris transversales al cordón de soldadura tienen la forma de una campana perfecta. Si aparece un defecto en el cordón, el resultado es una morfología anómala en el perfil. Esta anomalía la clasifican en tres categorías: pico, valle y concavidad que se muestran en la figura 2.4. El método de detección comprende cuatro etapas: módulo de preprocesado, módulo de ajuste de curva, módulo de detección de perfil anómalo y módulo de post-procesado. El módulo de preprocesado se utiliza para separar el fondo, realzar la imagen si esta es muy oscura y normalizar todas las imágenes al mismo nivel de gris. En este módulo se realiza un ajuste fuerte y otro ajuste apro-

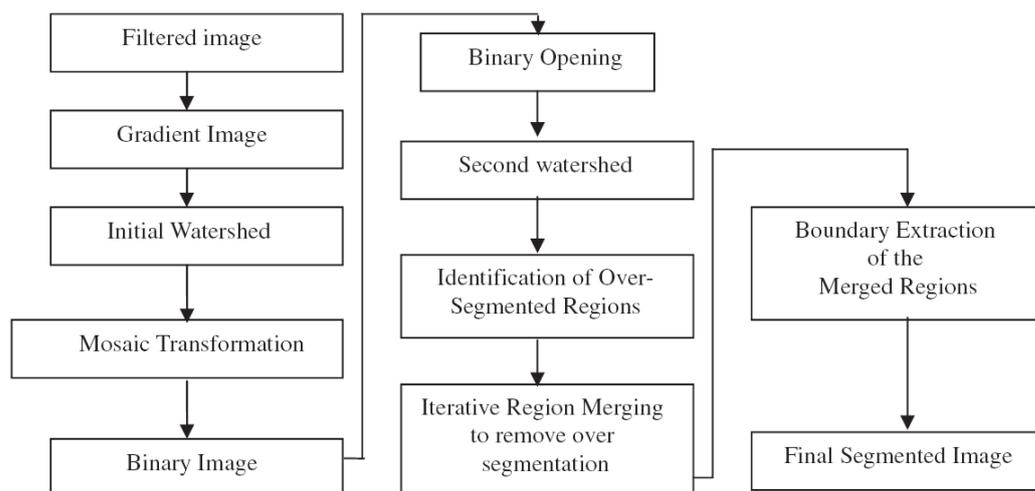


Figura 2.3: Proceso de segmentación de defectos propuesto. (Alaknanda et al. [2])

ximado, con lo que se suavizan los perfiles, mientras que el módulo de detección de perfiles anómalos detecta la existencia de anomalías en dichos perfiles. Para ello utiliza el perfil con ajuste fuerte para la detección de anomalías del tipo pico y valle y la comparación entre el ajuste fuerte y el aproximado para la detección de anomalías del tipo concavidad. Los resultados obtenidos de los perfiles se reúnen para generar un mapa bidimensional del defecto. El módulo de post-procesado aísla las anomalías que han sido identificadas en las etapas previas y actualiza los mapas de los defectos. Liao y Li reportan con este sistema un 93.3% de éxito.

Por otra parte, Jacobsen et al. [40] utilizan filtros en una dimensión, en el dominio de la frecuencia, para detectar fisuras y mordeduras en las radiografías. Para realzar las indicaciones de las fisuras longitudinales emplean un filtro paso-alto (operador *Bessel*), desarrollado en el *Federal Institute for Materials Research and Testing* (BAM) de Berlín para filtrar frecuencias iguales o mayores que las frecuencias relacionadas con la presencia de fisuras, lo que le permite aislar las dos clases de defectos.

Perner et al. [84] se basan en perfiles de niveles de gris perpendiculares a la dirección de la soldadura para la detección de grietas longitudinales y mordeduras de bordes en soldaduras realizadas en tuberías de acero austenítico. Tras una etapa de preprocesado de las imágenes tendente a realzar las pequeñas variaciones de niveles de gris en el fondo y eliminar ruido, se extraen 36 características de los perfiles basadas en las posiciones de máximos y mínimos locales y valores estadísticos de gradientes. Un esquema de este proceso se puede apreciar en la figura 2.5.

Padua et al. [82] se basan en los perfiles de niveles de gris para la detección de defectos mediante un procedimiento similar a la técnica de Liao y Li [55], [56], pero utilizando después un clasificador implementado mediante una red neuronal artificial. Para preprocesar los datos, inicialmente se reduce el ruido en la señal

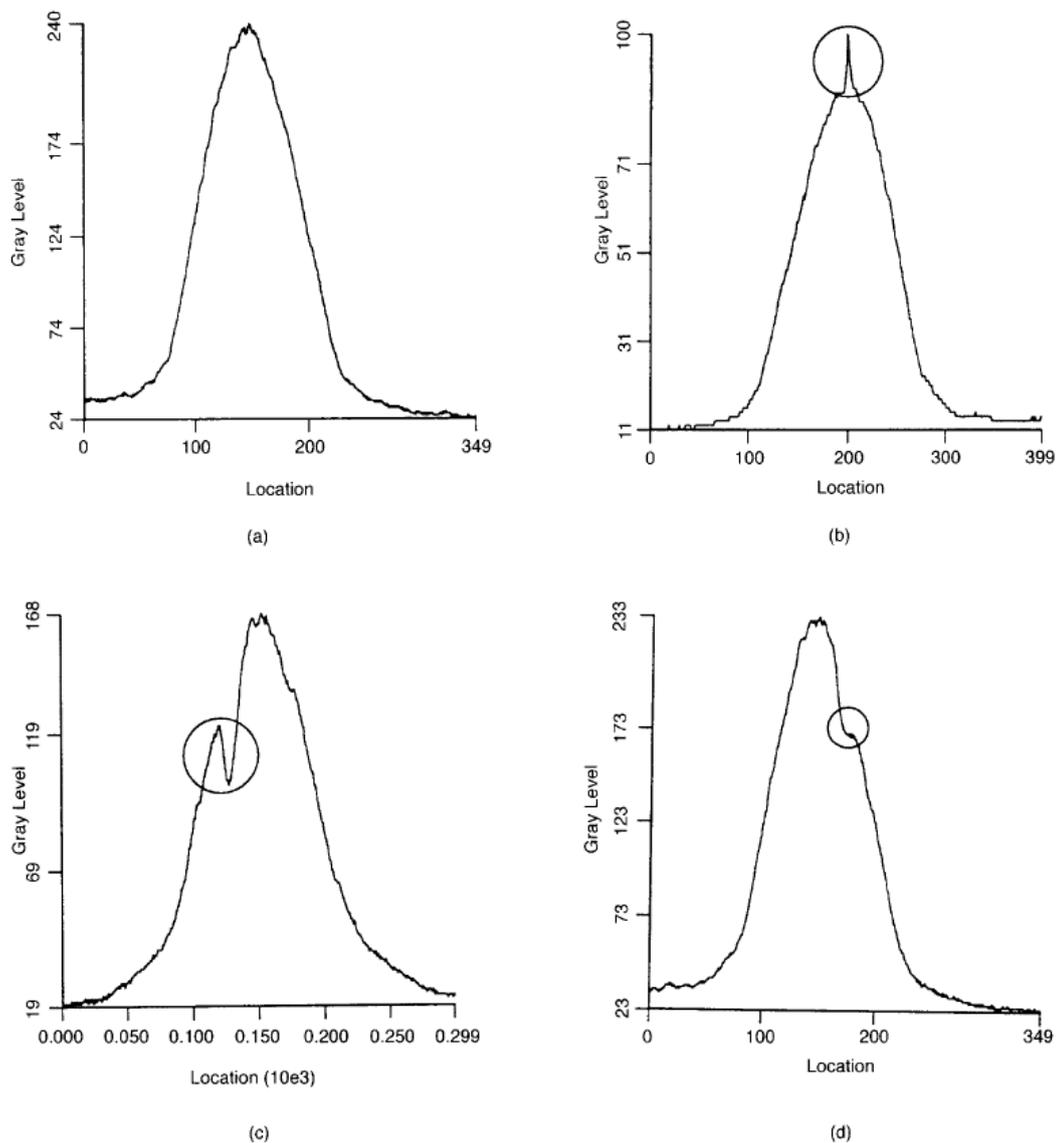


Figura 2.4: Perfiles de niveles típicos de: (a) cordón de soldadura sin defectos; (b) cordón con defecto pico; (c) cordón con anomalía tipo valle; (d) cordón con anomalía tipo concavidad. (Liao y Li [55])

empleando el filtro *Savitzky-Golay*. La elección del filtro se justifica en el hecho de que produce un menor descenso en la amplitud del valle/pico de un defecto que el causado por otro tipo de filtrado. Posteriormente, para normalizar la posición de los defectos con respecto al centro de la curva de ajuste Gaussiana basada en el perfil filtrado, todos los perfiles que tienen defectos a la izquierda de la mitad de la curva se invierten. Padua et al. consiguen un 80% de éxito en los test de detección de defectos cuando utilizan directamente los perfiles suavizados como entradas a los clasificadores no lineales, y un acierto del 88% cuando los perfiles se

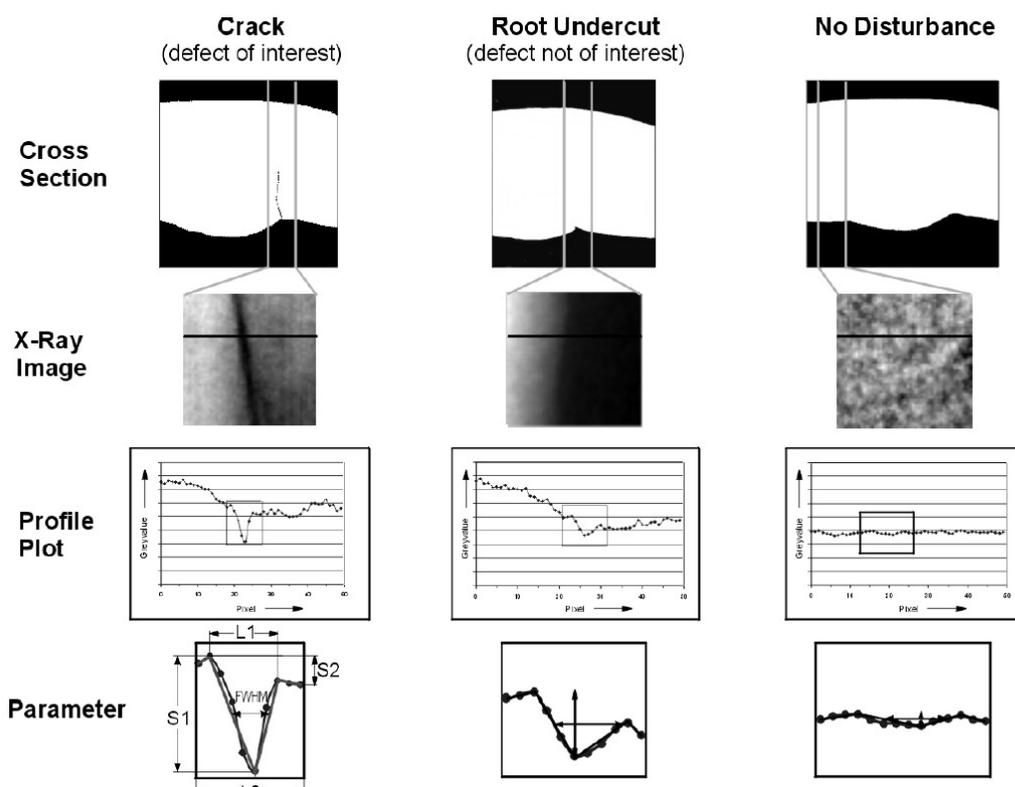


Figura 2.5: Esquema de análisis basado en perfiles. (Perner et al. [84])

normalizan previamente de acuerdo a la distribución de los defectos, demostrando que el preprocesamiento de los perfiles es muy importante en estos casos.

Liao et al. [53] proponen otro enfoque utilizando un procedimiento basado en métodos de clusterización borrosa. El procedimiento consiste en procesar la imagen del cordón de soldadura línea por línea, para seguidamente, de cada perfil original y de su correspondiente perfil ajustado (utilizando la técnica de ajuste *B-spline cúbico*), extraer 25 características. Liao et al. analizan el rendimiento de dos métodos de clusterización borrosa *fuzzy K-NN* y *fuzzy C-Means* para clasificar los objetos detectados, encontrando que el clasificador *fuzzy K-NN* supera al clasificador *fuzzy C-Means* con los mejores resultados de 6.01 % de defectos no detectados y 18.68 % de falsos positivos.

El trabajo de Nacereddine y Redouane [72] difieren de los referidos anteriormente en que en este caso no se utilizan perfiles de niveles de gris. Para detectar los bordes del defecto diseñan un clasificador neuronal que emplea una ventana de 3x3 píxeles que se desplaza por toda la imagen clasificando el píxel central. Por tanto, la ANN tiene 9 neuronas en la capa de entrada que reciben los niveles de gris de los píxeles de la ventana, y la capa de salida tiene sólo una neurona para clasificar en la salida la detección o no detección de el borde de un defecto, formando finalmente una imagen segmentada binaria. Para este trabajo se indica que los resultados son satisfactorios cuando antes de utilizar la red neuronal para segmentar la imagen

se hace un procesado de mejora del contraste de la radiografía. Un esquema del clasificador empleado se muestra en la figura 2.6

En un posterior trabajo Nacereddine et al. [75] implementan tres algoritmos diferentes de umbralización para la segmentación de las regiones candidatas a defectos. Uno de los métodos propuestos es el de umbralización global de Otsu [81] y los otros dos son los umbralizadores adaptativos locales de Niblack y Sauvola [78]. El método Otsu considera que el umbral debe de minimizar la suma ponderada de la varianzas de las clases, en nuestro caso defectos y fondo, ya que supone que conforme se aproxime esta al histograma real las desviaciones serán menores. En aquellas imágenes radiográficas en las que la intensidad del fondo es variable debido a las variaciones de espesor en el cordón y a la presencia de defectos de pequeño tamaño, y por tanto el solapamiento de las dos clases es grande, las umbralizaciones globales no obtienen los resultados deseados y se hace necesario el empleo de técnicas de umbralización adaptativas locales como el método propuesto por Niblack que resulta rápido de implementar y fácil de aplicar. La idea principal del método consiste en variar el valor del umbral basándose en la media local  $\mu(x, y)$  y la desviación standar local  $\sigma(x, y)$ , calculado con la expresión:

$$T(x, y) = \mu(x, y) + k\sigma(x, y)\sigma \quad (2.2)$$

En este método los problemas surgen con las texturas claras en el fodo de la imagen, que suelen ser consideradas como objetos con pequeño contraste. Para superar estos problemas Sauvola propuso una nueva expresión mejorada para calcular el umbral.

$$T(x, y) = \mu(x, y)[1 - k\alpha] \quad \alpha = \frac{1 - \sigma(x, y)}{R} \quad (2.3)$$

Es importante destacar que la aplicación de las técnicas de umbralización propuestas en este trabajo dan como resultado imágenes binarias que pueden contener información superflua que es deseable eliminar o información enmascarada que es necesario dejar ver. Por tanto, para conseguir la segmentación de los defectos es necesario aplicar una etapa de post-procesado basada en operadores morfológicos (dilatación, erosión, *opening* y *closing*) que permitan eliminar ruido y manchas residuales y conectar regiones cerradas que probablemente representan el mismo defecto.

Daum et al. [24] proponen un algoritmo de segmentación de defectos basado en una técnica de sustracción del fondo. Parten del hecho de que los defectos encontrados en una imagen se caracterizan por presentar un espectro de altas frecuencias, mientras que el cordón de soldadura se manifiesta como un cambio gradual en el nivel de gris (bajas frecuencias). Por esa razón, en el trabajo se simula un cambio gradual de nivel de gris con un modelo de fondo bi-dimensional y se resta de la imagen original. Este método puede aplicarse a todo tipo de defectos y también fue utilizado por Wang y Liao [102], quien lo integró con el algoritmo *surface-fitting*. Después de que el fondo se separa de la imagen, los defectos aún han de ser separados del ruido mediante una umbralización del histograma que discrimine entre defectos y fondo.

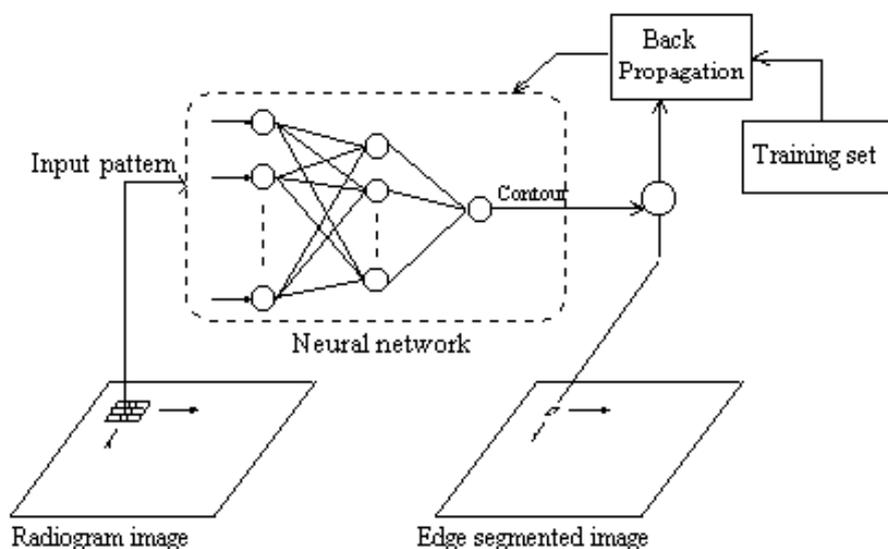


Figura 2.6: Arquitectura de la red neuronal. (Nacereddine y Redouane [72])

Gayer et al. [31] describen un proceso de dos etapas para el reconocimiento automático de defectos en radiografías. En la primera etapa para identificar y localizar defectos realizan una búsqueda rápida. Asumiendo que los defectos serán más pequeños que la estructura regular de la soldadura, los potenciales defectos se clasifican como aquellas regiones de la imagen donde las altas frecuencias son significativas. El espectro de la imagen radiográfica se obtiene con la ayuda de la transformada rápida de Fourier que se calcula fila a fila en una ventana de  $32 \times 32$ . Cuando la suma de las altas frecuencias de una ventana es mayor que un valor de umbral dado la ventana entera es marcada como candidato a defecto. En la segunda etapa se procede a confirmar o rechazar los defectos detectados anteriormente. Los autores desarrollan dos algoritmos para esta tarea. El primero realiza una búsqueda de coincidencia entre los potenciales defectos y defectos tipos almacenadas como plantillas en una librería (método secuencial de detección de similitud). Siempre que se encuentra una gran semejanza entre el potencial defecto y una plantilla, este es confirmado como verdadero defecto. El segundo algoritmo estima una imagen de la radiografía inspeccionada que esté libre de defectos. Seguidamente se comparan las imágenes originales y las estimadas identificando los defectos como verdaderos cuando se produzca una gran diferencia entre ambas imágenes. Este método intenta imitar la forma en que un inspector humano inspecciona radiografías: primero, un vistazo general, para concentrarse seguidamente de manera más fina en las regiones defectuosas.

Ishii et al. [38] y [39] proponen un método de detección de defectos basado en un modelo adaptativo. El método detecta objetos evaluando parámetros estadísticos locales, como el contraste espacial, y emplea reglas de razonamiento parecidas a las reglas heurísticas empleadas por los inspectores humanos. A diferencia de otros esquemas de razonamiento, no depende de ninguna forma de pre-normalización de las imágenes de entrada, y puede tratar imágenes de bajo contraste tan bien como otras de alto contraste. Aunque este método ofrece buenos resultados experimentales,

requiere de muchos parámetros y valores empíricos de umbral. En un intento de mejorar el rendimiento del método, Lashkia [45] introduce una nueva propuesta que implementa razonamiento borroso utilizando un sistema neuro-borroso, y que realiza el proceso de umbralización de forma suave y más flexible.

Mery y Berti [66] presentan una nueva propuesta para detectar defectos en soldaduras que sigue el esquema general del reconocimiento de patrones, esquema basado en tres etapas: 1) segmentación de potenciales defectos utilizando un detector de bordes basado en el operador laplaciano de Gauss, 2) extracción de dos grupos de características de textura ampliamente conocidas y 3) clasificación como *defecto* o *no-defecto* mediante clasificadores estadísticos que utilizan como conjunto de datos de entrada una selección de las características más relevantes. Los autores presentan los resultados obtenidos con tres clasificadores estadísticos, polinomial, Mahalanobis y clasificador *nearest neighbour* Euclídeo como en Mery et al. [67], obteniéndose los mejores resultados con el clasificador polinomial que detecta el 91 % de los defectos con un 8 % de falsos positivos.

A modo de resumen podemos decir que los algoritmos generales de procesamiento para detección de defectos en imágenes radiográficas de uniones soldadas que encontramos en la bibliografía adolecen de numerosos problemas. Los algoritmos que utilizan operadores de suavizado (*smoothing*) [43], [50] y [92] presentan dificultades para detectar pequeños objetos como grietas, que aparecen como sutiles cambios de matices en la imagen; cuando se utilizan estos operadores, los objetos pequeños de bajo contraste se hacen borrosos o desaparecen completamente. Los métodos basados en la substracción entre la imagen original y la imagen del fondo sin defectos [24] y [43] se muestran también incapaces con defectos pequeños de bajo contraste, ya que el procesado está fuertemente afectado por el tamaño y el contraste del defecto. Las técnicas de detección de bordes [41] y [50] son efectivas sólo cuando hay contraste significativo. Por contra, los métodos convencionales de segmentación de imágenes mediante umbralizaciones adaptativas [41] y [71] o iteraciones condicionadas [41], son incapaces de segmentar adecuadamente imágenes iluminadas incorrectamente.

## 2.5 Extracción y Selección de Características

La elección adecuada de las características relevantes para identificar cada clase de defecto es de importancia fundamental en el proceso de reconocimiento de defectos. Esta elección se basa en el proceso de interpretación seguido por un inspector que, la mayoría de las veces, reconoce el tipo de defecto en la imagen radiográfica, primeramente por características geométricas y de intensidad (posición, forma, dimensiones, nivel de gris, relación de aspecto, etc), además de observar también las condiciones del proceso de soldadura.

Uno de los trabajos más importantes en este campo de investigación, que se refiere a la discriminación de clases de defectos a través del empleo de características de forma, es el publicado por Aoki y Suga [4], en el que realizan la clasificación de los defectos según el procedimiento que se resume a continuación. Inicialmente, un candidato a defecto puede ser clasificado por la forma geométrica con que se presenta: circular o lineal. Seguidamente se aplican criterios que aprovechan la información

relativa a la posición del defecto y a otros parámetros representativos de sus características histográficas. Por ejemplo, cuando un defecto posee una forma circular, este puede ser clasificado como porosidad o como inclusión de escoria dependiendo de la forma del contorno, contraste y posición en el cordón de soldadura. Cuando un defecto tiene forma lineal y está localizado en el borde del cordón, probablemente se trate de una mordedura, mientras que si se localiza en el centro del cordón puede ser clasificado como grieta o falta de penetración.

En este estudio se definen 10 características para discriminar cinco clases de defectos: porosidades, inclusión de escoria, grietas, falta de penetración y mordeduras. Estas características se resumen gráficamente en la figura 2.7, y describen la localización del defecto dentro del cordón de soldadura ( $C_1$ ), la forma del defecto ( $C_2$  y  $C_6$ ) y su diámetro de *Heywound* ( $C_7$ ), el grado de circularidad del defecto ( $C_3$  y  $C_4$ ) la complejidad del contorno ( $C_5$ ), el promedio del nivel de gris en el defecto ( $C_8$ ), la dispersión de la intensidad o variación de los niveles de gris en los defectos ( $C_9$ ), y por último la diferencia de intensidad entre los niveles de gris del interior y el exterior de la imagen del defecto ( $C_{10}$ ).

En el trabajo desarrollado por Kato et al. [43] también se utilizan características para clasificar los defectos en cinco categorías: porosidades, falta de fusión, falta de penetración, grietas e inclusiones de tungsteno. En este trabajo se parte de la hipótesis de que los defectos pueden ser clasificados visualmente como lineales o circulares. En base a esto, definen las siguientes características: anchura, longitud, simetría, redondez, ángulo (entre el eje principal del defecto y el eje central del cordón), posición (en relación al centro del cordón) y nivel de gris del defecto. Sin embargo en este trabajo se pone de manifiesto la dificultad de encontrar las características que identifiquen los defectos típicos de soldaduras basándose solamente en la información contenida en la radiografía. La experiencia y modo de proceder de los inspectores justifican la necesidad de utilizar otras informaciones como: tipo de material de las piezas a soldar, técnica de soldadura utilizada, condiciones de soldadura y técnica de inspección radiográfica empleada.

Varios autores como Yue et al. [107], Lashkia [45] y Wen et al. [105], sostienen en sus trabajos que básicamente podemos clasificar los defectos en tres clases: defectos redondos (poros, inclusión de escoria, falta de penetración), defectos longitudinales (falta de fusión, falta de penetración, grietas) y defectos transversales (grietas). Coinciden en describir sus características de la siguiente forma: los poros son puntos esféricos y oscuros de contorno suave, niveles bajos (oscuros) en el centro y altos (claros) próximos al borde; las inclusiones son de forma de barra alargada y esférica, con niveles de gris no uniformes, y en donde los bordes no son suaves como las porosidades y de localización aleatoria en el cordón; la falta de fusión se sitúa entre el centro y el borde del cordón es de forma alargada y estrecha con contorno irregular; la falta de penetración se localiza en el centro del cordón, con forma alargada de contorno suave y regular; y las grietas poseen forma estrecha e irregular y con localizaciones, tamaño y orientación no regulares. Y encuentran relaciones parecidas entre las características geométricas y las clases de defectos establecidas por las normas internacionales. Estas son: si la relación ancho/largo es mayor que 3, entonces el defecto es lineal, en caso contrario es esférico; el defecto cuyo contorno es suave es un poro, en caso contrario es una inclusión de escoria. De acuerdo con

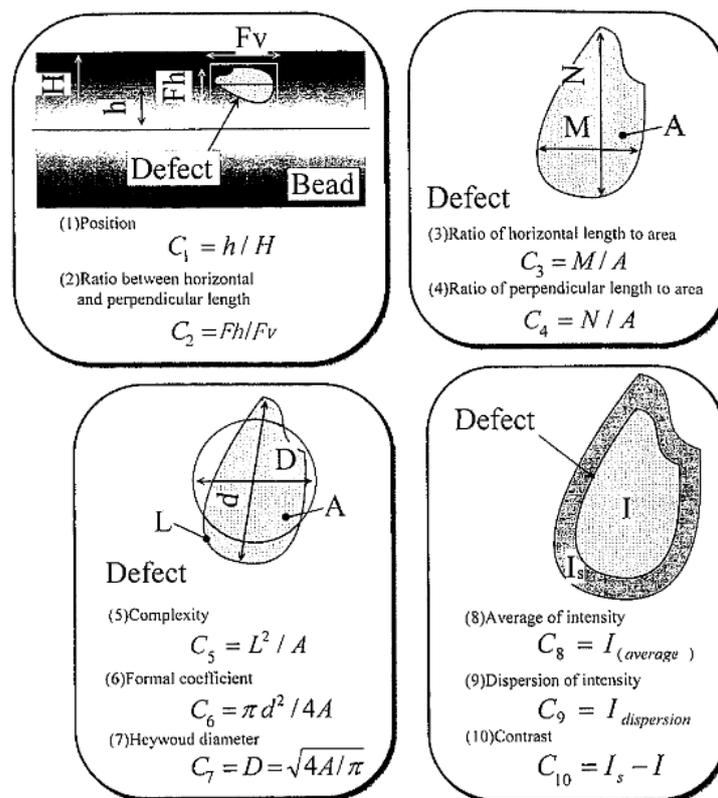


Figura 2.7: Definición de características. (Aoki y Suga [4])

la dirección del defecto podemos identificar al defecto cuya dirección sea horizontal como una grieta longitudinal, o en caso contrario, como defecto horizontal.

Para el reconocimiento de defectos, Nacereddine y Redouane [72], utilizando una combinación no lineal de los momentos centrales normalizados, deducen un conjunto de siete momentos que tienen la propiedad de ser invariantes a la translación, escalado y rotación de la imagen. Esos siete momentos se usan como características de entrada de un clasificador formado por una red neuronal con dos capas con función tangente hiperbólica y con algoritmo de entrenamiento *backpropagation*, en donde el número de neuronas en la capa oculta se determina de forma empírica y mediante la cual finalmente se clasifican las imágenes de los defectos en dos clases: defectos planos y defectos volumétricos.

Mery y Berti [66] proponen una técnica basada en dos características de textura. Aunque la textura es una de las características más importantes de las utilizadas en reconocimiento de patrones en imágenes, todavía no se emplean habitualmente en el análisis automático de imágenes radiográficas de uniones soldadas. En este trabajo se describen dos grupos de características de textura muy extendidas: características basadas en la matriz de concurrencia, que da una medida de con qué frecuencia un valor de gris aparecerá en un espacio específico relacionado a otro valor de gris de la imagen, y en características basadas en funciones 2D de Gabor. Las funciones de Gabor son filtros pasa banda Gaussianos, que representan una elección apropiada para tareas que requieren medidas simultáneas tanto en el dominio del espacio como

de la frecuencia. En los experimentos, el porcentaje de detección fue de 91%; sin bien el porcentaje de falsos positivos fue del 8%.

Wang y Liao [102] definen una serie de características para clasificar los defectos relativos a su forma y posición; *distancia al centro del cordón*, *redondez* (relación entre el perímetro al cuadrado y el área del defecto), *elongación* (razón entre la longitud y la anchura del defecto), *diámetro Heywood* e *intensidad media*. Estos autores utilizan ese conjunto de características para formar los datos de entrada de dos clasificadores no lineales: uno utilizando una red neuronal de dos capas, y otro implementado por el algoritmo *fuzzy K-NN*. Con estos clasificadores separan seis clases de defectos: grietas, poros, inclusiones de hidrógeno, falta de fusión y falta de penetración. Wang y Liao resaltan en su artículo que, por tener un conjunto de imágenes ejemplo reducido para estas clases, usan métodos como validación cruzada y *bootstrap* para verificar el rendimiento de sus clasificadores. La red neural entrenada con 108 defectos consiguió como resultado un 92.39% de media de acierto frente a un 91.57% del clasificador borroso.

Da Silva et al. [19] y [20], inicialmente utilizaron seis características para definir cinco clases de defectos: inclusiones no lineales de escorias, inclusiones lineales de escoria, poros, falta de penetración y mordeduras. Estas características son las que se destacan en la figura 2.8:

- *Contraste*: relación entre la variación del nivel de gris en el defecto y en la imagen completa.
- *Posición* ( $P = h/H$ ): facilita la localización del defecto en relación con el centro del cordón de soldadura.
- *Aspecto* ( $a = L/e$ ): se utiliza para separar las clases de defectos más esféricos (poros), de los defectos menos esféricos (falta de penetración y inclusiones lineales).
- *Relación entre ancho y área* ( $e/A$ ): mide la circularidad del defecto.
- *Relación entre longitud y área* ( $L/A$ ): mide la circularidad del defecto.
- *Redondez* ( $R = p^2/4\pi A$ ), donde  $p$  es el perímetro: cuando la forma del defecto se aproxima a un círculo, este parámetro tenderá a 1. La correlación de estos seis parámetros con las clases de defectos la evalúa analizando el coeficiente de correlación lineal, bien conocido en estadística.

Una técnica proporcionada por Silva et al. [19], [20], [21] es utilizada para evaluar la capacidad de discriminar los parámetros característicos mediante el criterio de relevancia utilizando la ecuación presentada por Seixas [87], cuyo valor depende del rendimiento de la red. Se han analizado los cambios en la respuesta de la red neuronal cuando el valor de los parámetros se reemplaza por su valor medio obtenido cuando se consideran todos los patrones de entrenamiento, en cuyo caso la red responde de una manera completamente diferente. Consecuentemente, los parámetros más importantes presentarán los valores mayores de relevancia. Con este criterio se consiguen, con sólo los parámetros  $a$ ,  $e/A$ ,  $R$  y  $P$ , los mismos resultados

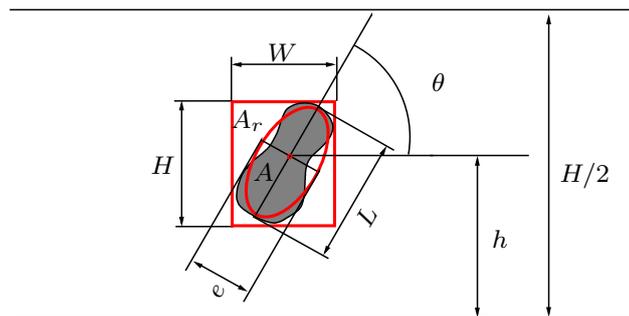


Figura 2.8: Definición de características. (Da Silva et al. [19], [20] y [21])

que los obtenidos con los seis parámetros. Es decir, eliminan los parámetros  $C$  y  $L/A$ .

En posteriores trabajos [16] y [21], estos autores utilizan siete características para identificar seis tipos de defectos: falta de fusión, falta de penetración, mordeduras, grietas, inclusiones de escoria y poros, mediante la utilización de una red neuronal. En este caso aparecen tres nuevas características respecto a las cuatro seleccionadas en los trabajos anteriores:

- *Angulo* ( $\theta$ ): el ángulo entre el eje mayor del defecto y la vertical.
- *Área/rectángulo* ( $A/A_r$ ): relación entre el área del defecto y el menor rectángulo que encierra el defecto.
- *Límites rectángulo* ( $W/H$ ): relación entre el ancho y el alto del menor rectángulo que encierra el defecto.

Concluyen que el mejor rendimiento del clasificador de defectos (99.16 %) se obtiene cuando se utilizan como características discriminantes: *Aspecto*, *Área/rectángulo*, *Ángulo* y *Redondez*.

Otra aproximación es la presentada por Shafeek et al. [88] y [89]. Utilizan un algoritmo de identificación de defectos (DIA) mediante un árbol de decisión, para clasificar los defectos extraídos, basado en la pericia humana en el campo de la inspección. El proceso de identificación está basado en la estimación de tres factores principales de los defectos, como son: la forma, orientación y localización. Además, utilizan algunos factores secundarios para completar el proceso de identificación tales como: número de defectos, ancho y tamaño del defecto y rectitud del defecto. El identificador DIA clasifica entonces la forma del defecto en tres categorías: circular, rectangular e irregular, introduciendo dos factores para identificar la forma de las regiones. El primer factor lo llama factor de forma ( $F_f$ ) y lo utiliza para medir la circularidad de las regiones basándose en su área y su perímetro. Para regiones circulares, el factor de forma es igual a 1.0, si bien es necesario contemplar cierta tolerancia ( $\pm 10\%$ ) a fin de identificar correctamente los defectos circulares. El segundo factor utilizado para identificar la forma de los defectos lo llama factor de rectangularidad ( $R_f$ ). Lo utiliza para medir la rectangularidad de las regiones basándose en la relación entre el área de la región y el área del mínimo rectángulo que encierra a el defecto, de forma que este factor será igual a 1.0 para regiones

rectangulares. Para identificar la forma del defecto, se calcula en primer lugar ( $F_f$ ); si su valor se mantiene entre 0.90 y 1.10, el defecto se considera de forma circular, y en caso contrario se calcula el factor de rectangularidad y se aplica el mismo criterio numérico para determinar si su forma se considera rectangular; si no es así el defecto es catalogado como irregular. La orientación se utiliza solamente para defectos alargados y se calcula teniendo en cuenta su longitud y su ancho. La localización de los defectos es necesaria para identificar defectos tanto irregulares como alargados. En este trabajo distinguen cuatro posibles localizaciones: *Inside Weld* (IW), *Center of Weld* (CW), *Edge of Weld* (EW) y *Base Metal* (BM). Para establecer la pertenencia de un candidato a defecto en una de las localizaciones se calculan las coordenadas del centro de gravedad y del rectángulo de inclusión (*bounding box*) del defecto.

Nacereddine et al. [73] y [74] calculan para cada defecto un conjunto de parámetros geométricos, que hemos reproducido en la figura 2.9: área ( $A$ ), perímetro ( $P$ ), centro de gravedad ( $G(x, y)$ ), ángulo de orientación ( $\alpha$ ), ejes principales de inercia, ancho ( $W$ ) y longitud ( $L$ ) del rectángulo circundante, diámetro máximo ( $D_{max}$ ), radio del máximo círculo inscrito ( $R_{max}$ ), áreas parciales ( $S_1, S_2, S_3$  y  $S_4$ ), semiejes mayor y menor ( $a, b$ ) de la elipse. Con estos parámetros los autores definen propiedades geométricas que son invariantes frente a traslaciones, rotaciones o cambios de escala.

Del examen de un conjunto completo de radiografías y sobre la base de las características morfológicas de los defectos, Nacereddine et al. definen cuatro categorías principales de formas de defectos. En la primera categoría se incluyen los defectos en los que la forma es alargada, afilada, puntiaguda y rectilínea, como ocurre en los casos de grietas, mordeduras y falta de fusión. La segunda categoría incluye los defectos en los que la forma es alargada, alisada, suave y rectangular; a esta categoría corresponden la falta de penetración, los poros alargados y las porosidades. En la tercera categoría se incluyen los defectos con forma esférica, es decir, porosidades, inclusiones de Tungsteno, etc. Por último, la cuarta categoría comprende los defectos en los que la forma es irregular, no alargada y no esférica; en esta categoría estarían las inclusiones de escoria.

Por último, Lim et al. [59] desarrollan un sistema de clasificación utilizando un gran número de imágenes simuladas de defectos de soldaduras que son considerados como ideales. De ese banco de datos extraen un conjunto de 25 descriptores habituales de forma que son evaluados para determinar su capacidad de discriminación de los diferentes tipos de defectos. Con objeto de elegir una combinación de características óptimas que proporcionen la mayor capacidad de clasificación, los autores realizan varios procedimientos de comparación mediante un enfoque estadístico. Finalmente llegan a seleccionar un conjunto de 9 descriptores que acumulan la mayor capacidad discriminatoria.

## 2.6 Identificación y Clasificación de Defectos

La última etapa de un sistema de inspección de imágenes radiográficas de uniones soldadas corresponde a la tarea de identificación y clasificación de los candidatos a defectos detectados en anteriores etapas. Para ello se aplican técnicas de reconoci-

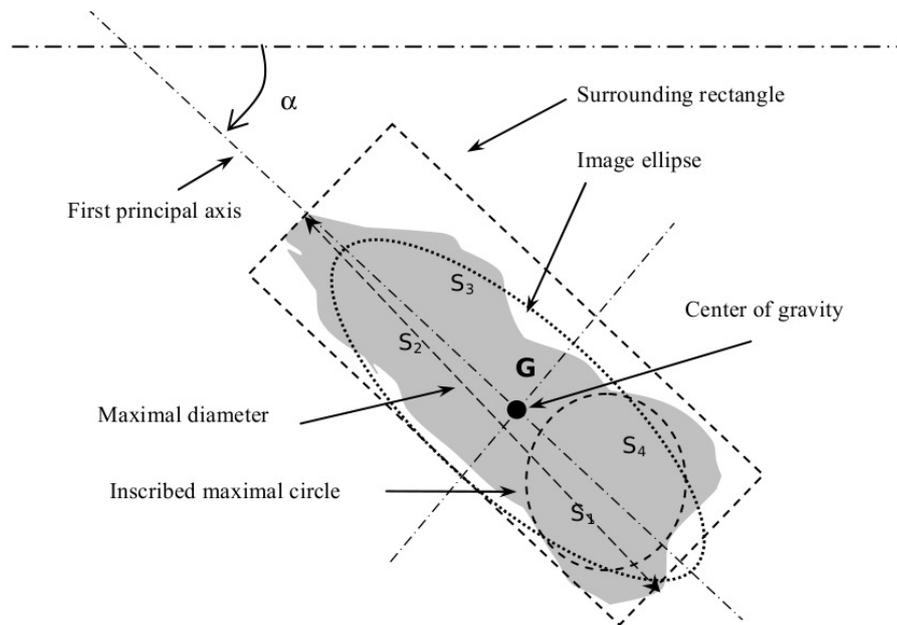


Figura 2.9: Definición de características geométricas. (Nacereddine et al. [73] y [74])

miento de patrones basados en clasificadores estadísticos, redes neuronales o lógica borrosa. Esta etapa probablemente sea la que ha dado lugar a un menor número y diversidad de propuestas por lo que son escasos los trabajos que podemos comentar en esta revisión bibliográfica.

Comenzando por las propuestas basadas en sistemas expertos, Murakami [71] clasifica los diferentes tipos de defectos mediante un sistema experto. Las características utilizadas por el sistema incluyen la forma, posición y nivel de intensidad, pero los resultados dependen de manera importante de los tipos de defectos.

Kato et al. [43] proponen otro sistema experto para inspección de soldaduras, en el que las reglas para la identificación de los defectos se generan de dos formas complementarias. Por una parte utilizan una base de datos integrada por imágenes de radiografías, de la cual, para cada clase de defecto, estudian el factor de correlación entre parejas de diez características extraídas de los defectos y sus distribuciones de frecuencia, y por otro lado basándose en la calidad de la información obtenida mediante entrevistas con expertos inspectores.

Da Silva et al. [19], [20] y [21], proponen la utilización de clasificadores lineales como técnica de reconocimiento de patrones para resolver el problema de la clasificación de defectos de soldaduras. En sus trabajos presentan una forma de obtener los mejores discriminadores lineales jerárquicos y no-jerárquicos que sean capaces de clasificar algunos de los principales defectos que podemos encontrarnos en inspección radiográfica de uniones soldadas, utilizando para su implementación una red neuronal. El uso de discriminadores lineales óptimos es una técnica utilizada en estadística conocida como *Fisher Discriminator*. Los resultados obtenidos indican que los índices de éxito son mejores cuando se utiliza el algoritmo jerárquico, obteniéndose un porcentaje de éxito del 85 %.

En un trabajo posterior, Da Silva et al. [22], con un enfoque distinto al de los trabajos previos, introducen un clasificador no-lineal para intentar incrementar el porcentaje de éxito del sistema de inspección. El clasificador fue implementado utilizando una red neuronal con dos capas, una capa intermedia y una de salida, utilizando el algoritmo de *backpropagation* para el entrenamiento de la red. Un aspecto importante de este trabajo es la utilización de una técnica analítica bien conocida en otras aplicaciones pero todavía no explotada en reconocimiento de defectos de soldadura, como es la discriminación por componentes principales no lineales como un recurso para la visualización en dos dimensiones de la representación espacial de las clases.

En un trabajo más posterior, Da Silva et al. [23] abordan el estudio de las metodologías y técnicas idóneas para estimar la fiabilidad o exactitud de los resultados obtenidos por los clasificadores de defectos. Aprovechando la disponibilidad de nuevas colecciones de radiografías patrones de soldaduras conteniendo defectos, consiguen aumentar significativamente el número de datos para calcular los parámetros del clasificador. Utilizando técnicas de inferencia estadísticas de selección aleatoria de datos con la técnica *Bootstrap*, crearon 50 conjuntos de datos de entrenamiento y 50 de test para estimar la exactitud del clasificador no-lineal definido en anteriores trabajos [19], [20] y [21].

Wang y Liao [102] describen la utilización de las características extraídas en la etapa previa para formar los datos de entrada de dos clasificadores no lineales: uno utilizando una red neuronal de dos capas (MLP), y otro implementado por el algoritmo *fuzzy K-NN*. Con estos clasificadores separan seis clases de defectos: grietas, poros, inclusiones de hidrógeno, falta de fusión y falta de penetración. Wang y Liao resaltan en su artículo que, por tener un conjunto reducido de imágenes ejemplo para estas clases, usan métodos como validación cruzada y *bootstrap* para verificar el rendimiento de sus clasificadores. La red neural entrenada con 108 defectos consiguió como resultado un 92.39% de media de acierto frente a un 91.57% del clasificador borroso. Los autores señalan que en el caso del clasificador borroso la elección del valor del parámetro  $k$  puede hacer variar la exactitud de los resultados en hasta un 15%, y que desafortunadamente no está resuelto el problema de la determinación de su valor óptimo.

Liao [51] presenta una nueva propuesta para la clasificación de diferentes tipos de defectos de soldaduras utilizando un sistema experto borroso. El problema de la adquisición del conocimiento y la generación de reglas lo aborda utilizando dos mecanismos de aprendizaje diferentes. Por un lado utiliza el método de generación de reglas borrosas mediante aprendizaje desde ejemplos, propuesto por Wang y Mendel [103], y que se desarrolla en cinco fases: en la primera fase se dividen los conjuntos de entrada y salida en regiones borrosas; en segundo lugar se generan las reglas desde los datos numéricos contenidos en los ejemplos; seguidamente se asignan grados a las reglas generadas con objeto de resolver conflictos de redundancia; en cuarto lugar se crea una base de reglas formada tanto por las generadas como por las lingüísticas obtenidas de los expertos; por último, en una quinta fase, se determina una estrategia a partir de los conjuntos de entrada y salida, basándose en las reglas borrosas combinadas y utilizando un procedimiento de desborrosificación. Como una mejora de este método, Liao utiliza el algoritmo de Goldberg [32] para modificar la primera etapa del método anterior consiguiendo variar de este modo el número

de particiones de cada universo de discurso ayudando así a determinar el número óptimo. A esta mejora la denominó método *SGA-WM*. En este trabajo se evalúan y comparan la precisión de los sistemas de clasificación de defectos utilizando los dos métodos para generar reglas borrosas, demostrándose que el método propuesto por el autor mejora los resultados del primero.

Nacereddine et al. [73] y [74] presentan una propuesta de clasificación de los principales defectos que se encuentran en inspección radiográfica utilizando una red neuronal artificial (ANN) entrenada con el algoritmo *backpropagation*. La clasificación la hacen asignando cada defecto a una de las cuatro categorías en las que los agrupan y que fueron comentadas en apartados anteriores. Inicialmente en la fase de entrenamiento los pesos se inicializan con valores aleatorios y la red se entrena con los vectores formados por los cuatro componentes principales obtenidos mediante análisis de componentes principales (PCA) del vector de características invariantes y sus correspondientes categorías. Como se muestra en la figura 2.10, el número de neuronas en la capa oculta definido de manera empírica es de diez y las cuatro neuronas de la capa de salida están dispuesta para reconocer cada categoría de defecto. El conjunto de entrenamiento está integrado por defectos identificados por expertos, mientras que el conjunto de prueba lo integran defectos desconocidos. Los resultados obtenidos muestran que casi la totalidad de los defectos que fueron catalogados por la ANN correspondieron a las interpretaciones realizadas a priori por los expertos con una precisión del 95 %. Solamente una categoría de defectos definida como falta de penetración fué clasificada de manera errónea por el clasificador neuronal que lo incluía en la categoría de grietas o mordeduras.

Una de las más importantes contribuciones en este campo de investigación relacionado con la discriminación entre clases de defectos mediante la utilización de características de forma es la realizada por Aoki y Suga [4]. Utilizan una red neuronal supervisada con algoritmo de error *backpropagation* cuya arquitectura se muestra en la figura 2.11. La red consta de tres capas; la capa de entrada contiene diez neuronas que almacena los valores de las diez características calculadas de los defectos segmentados en una etapa anterior, siete neuronas contiene la capa oculta y cinco neuronas la capa de salida (para reconocer cinco clases de defectos). Para verificar la eficiencia de cada una de las diez características, los autores evalúan la efectividad de la red retirando una característica cada vez, llegando a la conclusión de que el mejor rendimiento se obtiene cuando se utilizan todas las características estudiadas. Sobre el rendimiento de la red concluyen que de 27 defectos analizados 25 fueron correctamente clasificados, dando un índice de acierto de 92.6 %.

Jacobsen et al. [40], utilizan redes neuronales con algoritmo de entrenamiento *backpropagation* para clasificar dos tipos de defectos en radiografías de soldaduras de acero inoxidable: mordeduras y grietas longitudinales. Sus resultados evidencian un porcentaje de acierto en la clasificación de grietas del 97.0 % y del 90.0 % para mordeduras, cuando utiliza los datos del conjunto de test; cuando utilizan los datos del conjunto de entrenamiento estos porcentajes se reducen al 82.58 % para grietas y 88.74 % para mordeduras. Estos resultados, que no son explicados por los autores, son peculiares, ya que normalmente los mejores resultados se obtienen con los datos de entrenamiento. Se realiza también en este trabajo un estudio de la relevancia de

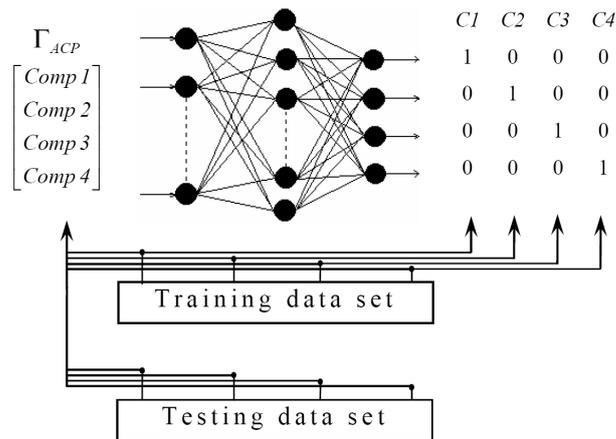


Figura 2.10: Configuración de la ANN utilizada por Nacereddine. (Nacereddine et al. [73] y [74])

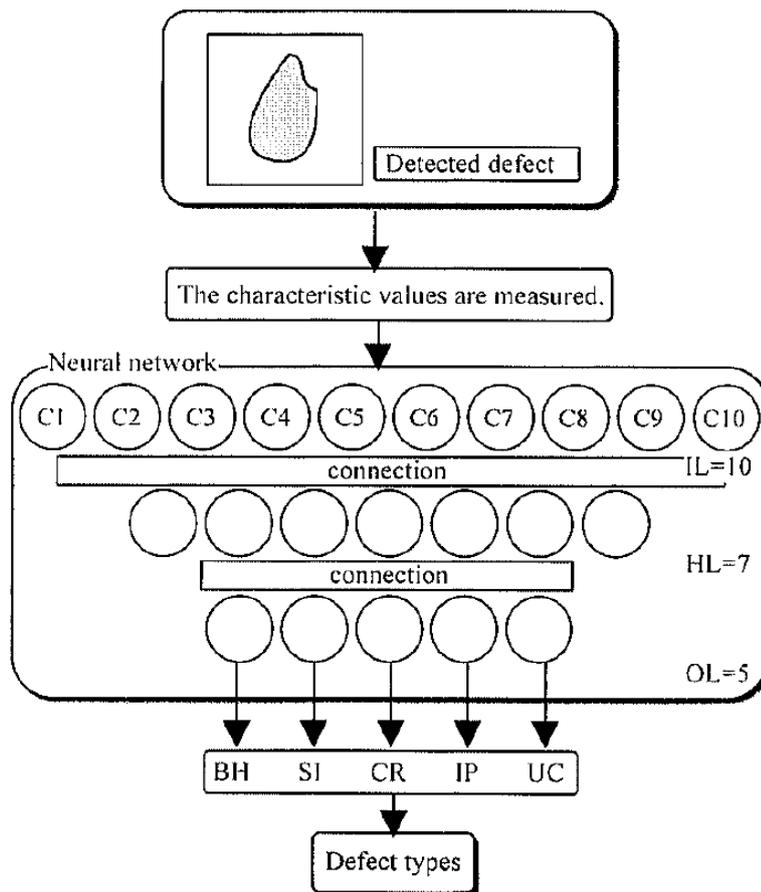


Figura 2.11: Arquitectura de la red neuronal supervisada de Aoki. (Aoki y Suga [4])

las características utilizadas como entradas en la red neuronal, para lo cual varían el valor de una característica y verifican la respuesta de la red a este cambio.

Perner et al. [84], utilizan para clasificar grietas longitudinales y mordeduras de bordes en imágenes radiográficas de soldaduras de tuberías de acero austenítico, cuatro tipos distintos de redes neuronales; backpropagation, RBF (*Radial Basis Function*), fuzzy ARTMAP y LVQ (*Learning Vector Quantization*), con algoritmo de aprendizaje basado en el método del gradiente descendente. Las entradas a la red son siete características seleccionadas mediante la técnica de análisis de parámetros significativos, de entre treinta y seis parámetros calculados de los perfiles de niveles de gris realizados sobre las regiones de las imágenes. En este trabajo y con el mismo objetivo, se utiliza un árbol de decisión que emplea para la selección de atributos el criterio de minimización de entropía [85] y para su discretización el método descrito por Perner y Trautzsch [83].

Para completar esta revisión, indicar que en el trabajo de Lim et al. [59] se desarrolla un sistema de clasificación utilizando un gran número de imágenes simuladas de defectos de soldaduras que son considerados como ideales. En la figura 2.12 se muestran algunos ejemplos de esas imágenes simuladas. El proceso de generación de las imágenes de defectos simulados se realiza en tres etapas: 1) radiografías reales de uniones soldadas conteniendo defectos son digitalizadas, 2) las imágenes obtenidas son sometidas a un proceso de detección de bordes Sobel, 3) el resultado son bordes irregulares y discontinuos que son retocados manualmente para unir los bordes interrumpidos y eliminar ruido. De ese banco de datos los autores extraen un conjunto de 25 características optimizadas mediante un enfoque estadístico a un conjunto de 9 descriptores con mayor capacidad discriminatoria. El proceso de clasificación lo realizan en dos partes. En primer lugar, una red neuronal perceptron multicapa o MLP (*Multi-Layer Perceptron*) entrenada con las características extraídas de los defectos simulados, se encarga de clasificar un conjunto de este tipo de defectos. En segundo lugar, la clasificación se realiza utilizando características extraídas de defectos reales. Los tests realizados con 60 defectos simulados desconocidos proporcionaron la efectividad máxima de clasificación (100%). La clasificación de 49 defectos reales procedentes de radiografías digitalizadas obtuvo un resultado total de efectividad de clasificación del 97.96%.

## 2.7 Sumario

Analizadas las principales publicaciones en este campo de investigación, se puede inferir que no existen reglas establecidas que definan un procedimiento para realizar un sistema automático de inspección de radiografías. Por el contrario, este análisis bibliográfico revela una amplia diversidad de técnicas en cada una de las etapas de que consta este tipo de sistemas, a pesar de las similitudes que se aprecian entre alguna de las propuestas. En este sentido resulta clarificador el resumen comparativo realizado por Silva y Mery [17] y [18] en el que se analizan las diferentes aproximaciones de los trabajos en este campo, identificando las técnicas empleadas en cada etapa e indicando los resultados obtenidos como se muestra en la tabla 2.1.

En general, la mayoría de los autores como en [3], [4], [62], [65], [66], [71] y [93]

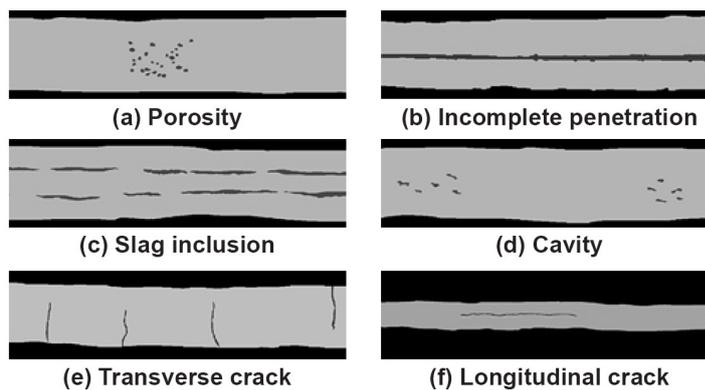


Figura 2.12: Imágenes simuladas de varios tipos de defectos. (Lim et al. [59])

aplican técnicas de mejora de la calidad de la imagen tales como la aplicación de filtros digitales antes de seguir adelante con la detección y clasificación de defectos. Esto es razonable, porque cuanto mejor sea la calidad de la imagen con respecto a contraste y ausencia de ruido, más fácil será la etapa de segmentación, detección de defectos, y más tarde clasificación de los tipos de defectos encontrados. Por tanto, es un denominador común en todas las propuestas de sistemas de inspección de soldaduras una etapa de preprocesamiento en la que se utilizan técnicas de reducción-eliminación de ruido mediante la aplicación de filtros pasa-bajo y técnicas de optimización del contraste principalmente extensión del contraste y equalización del histograma.

Son pocos los autores [27], [48], [52], [54], [56] y [57] que introducen en sus sistemas de inspección automática una etapa de segmentación del cordón de soldadura para definir así una región de interés con menor cantidad de información a procesar. En la mayoría de los casos la metodología utilizada se basa en el estudio de perfiles de niveles de gris trazados perpendicularmente al eje longitudinal de la dirección de soldeo, de los que se extraen características que finalmente son empleadas para la identificación definitiva del cordón. Para esta última tarea son varias las propuestas que podemos encontrar, desde la utilización de clasificadores borrosos que emplean algoritmos como *fuzzy K-NN* o *fuzzy C-Means* [48], [52] y [54] para la generación de las reglas, a la identificación empleando redes neuronales MLP [57], o al diseño de algoritmos específicos diseñados a la localización de picos y valles que son identificados con la situación del cordón [56].

La etapa de segmentación de los defectos es abordada en numerosos trabajos utilizando muy variados enfoques, desde las técnicas de segmentación más comunes que hacen uso de una serie de filtros que buscan variaciones en los píxeles como detectores de bordes (por ejemplo *Canny*, *Deriche*, *Prewitt* en [12] y [33]), las técnicas conocidas como de crecimiento de regiones [12], o la transformada de *Watershed*, hasta la utilización de técnicas de sustracción del fondo o la aplicación de diferentes algoritmos de umbralización locales, globales o adaptativos. También es frecuente encontrar trabajos que siguen otra línea de investigación tratando de conseguir la detección de los defectos mediante el estudio del perfil de intensidad de los niveles de grises trasversal al cordón de soldadura.

Por último, con respecto a la etapa de clasificación de defectos, en la mayoría de los trabajos se emplean técnicas de reconocimiento de patrones utilizando clasificadores no lineales como redes neuronales artificiales [4], [22], [59], [73], [74] y [84], o sistemas expertos clásicos [43] y [69], o basados en razonamientos borrosos [51] y [102].

Autores	Adquisición	Preprocesado	Segmentación	Detección	Características	Selección	Clasificador
T. Wang y T. Liao[102]	Scanner	F. Mediana Mejora contraste	Substracción del fondo	Umbralización histograma	Geométricas e intensidad	-	ANN
T. Liao [56],[55]	Scanner	Perfiles de niveles	Extracción del cordón	-	Geométricas	-	Alg. específico ANN;Borroso
H.Shafeek. [89],[88]	CCD	Ecuación F. Mediana	Umbralización local	Algoritmo código cadena	Geométricas	-	Arbol de decisión
K. Aoki[3], [4]	CCD	Ecuación Histograma	Substracción del fondo	-	Geométricas	Test empírico	ANN
K. Murakami [70]	Cámara Vidicom	Filtro pasa-bajo	Secuencia de filtros	-	Geométricas	-	Arbol de decisión
Y. Cherfa[14]	Scanner	Elim. ruido Ext. contraste	Detección de bordes	Crecimiento de regiones	Geométricas	-	Límites simples
C. Jacobsen [40]	Scanner	-	F. pasa-alto F. FFT	Filtros morfológicos	Medidas en perfiles	-	ANN;Borroso -ARTMAP
Nacereddine[72]	-	Mejora del contraste	ANN y Alg. de cierre	-	Geométricas	-	ANN
G.X. Padua [82]	Scanner	F. Savitzky -Golay	-	-	Perfiles de gris	-	ANN
R. Silva[20]	Scanner	F. mediana y Ecuación	Umbralización local	-	Geométricas e intensidad	Corr. lineal crit. relevancia	ANN
D. Mery[66]	Scanner	F. mediana y Ext. contraste	Laplaciana Gaussiana	Zero Crossing	Textura	ROC Crit. Fishers	-

Tabla 2.1: Principales aspectos técnicos de las técnicas utilizadas por los autores citados.



# Capítulo Tres

---

## Reconocimiento de Patrones mediante ANN y ANFIS

---

En este capítulo se pretende hacer una breve revisión de los conceptos básicos en reconocimiento de patrones, y en particular en las soluciones planteadas desde la perspectiva del denominado *soft computing*. Para ello será necesario presentar los conceptos introductorios sobre redes neuronales artificiales (ANN), la lógica borrosa (FL) y los sistemas de inferencia adaptativos neuroborrosos (ANFIS). El objetivo de esta revisión no es otro que proporcionar una visión general y resumida de este tipo de sistemas a aquellos expertos en el campo de los ensayos no-destructivos y la ingeniería de inspección de equipos, cuyo ámbito de conocimiento no tiene porqué extenderse al campo de los sistemas de computación conexionistas o la lógica borrosa. Sin embargo, la comprensión de los aspectos esenciales de estos paradigmas van a resultar imprescindibles para entender y valorar las técnicas aplicadas dentro del esquema de procesamiento de imágenes propuestas en esta tesis doctoral.

### 3.1 Reconocimiento de Patrones

¿Qué es un patrón? Siguiendo la definición de Watanabe [104], un patrón es una entidad a la que se le puede dar un nombre y que está representada por un conjunto de propiedades medidas y las relaciones entre ellas denominado *vector de características*. Por ejemplo, un patrón puede ser una imagen de una cara humana de las cuales se extrae el vector de características formado por un conjunto de valores numéricos calculados a partir de la misma.

Un sistema de reconocimiento de patrones tendrán como objetivos:

1. Identificar el patrón como miembro de una clase ya definida (*clasificación supervisada*).
2. O bien, asignar el patrón a una clase todavía no definida (*clasificación no supervisada, agrupamiento o clustering*).

El diseño de un sistema de reconocimiento de patrones se lleva a cabo normalmente en tres fases: adquisición y preprocesado de datos, extracción de características, y toma de decisiones o clasificación.

El *universo de discurso* o *dominio del problema*, gobierna la elección de las diferentes alternativas en cada paso: tipo de sensores, técnicas de preprocesamiento, modelo de toma de decisiones, etc. Este conocimiento específico del problema está

implícito en el diseño y no se representa como un módulo separado como sucede, por ejemplo, en los sistemas expertos.

Normalmente, el conjunto de objetos de entrada se considera dividido en una colección  $K$  de clases  $(\alpha_1, \alpha_2 \dots \alpha_k)$ , perteneciendo los diferentes objetos a algunas de estas clases,

Para poder realizar el reconocimiento automático de los objetos se realiza una transformación que convierte un objeto del universo de discurso en un vector  $\mathbf{X}$  cuyas  $\mathbf{N}$  componentes se denominan características discriminantes o rasgos. Estas características deben permitir discriminar a qué clases puede pertenecer cualquier objeto del universo de discurso, y el valor del vector de características para un objeto concreto es lo que se conoce como patrón. Es decir, un patrón es una instancia particular de un vector de características determinado.

Una vez determinadas las características discriminantes para un problema concreto, la clasificación de un objeto comienza por la obtención de su patrón. El siguiente paso consiste en determinar la proximidad o grado de pertenencia de este patrón a cada una de las clases existentes. A este efecto se definen las funciones discriminantes o funciones de decisión como aquellas funciones que asignan a un patrón un grado de semejanza respecto a cada una de las diferentes clases. En la figura 3.1 se muestra el esquema general de un Sistema de Reconocimiento de Patrones.

Para poder realizar el cálculo de las funciones discriminantes suele precisarse de un conjunto de patrones similares a los que se desea reconocer, que se denomina *conjunto de aprendizaje o conjunto de entrenamiento*. Los patrones de este conjunto se utilizan a modo de modelos para crear la función discriminante que clasificará correctamente los patrones del universo de discurso. Por eso, el conjunto de aprendizaje debe estar constituido por un subconjunto representativo del universo de discurso.

Cuando la muestra es abundante, suele crearse otro conjunto con ella. Este segundo conjunto se utiliza para probar los resultados de las funciones discriminantes calculadas, y se conoce como *conjunto de test*. Es importante que el conjunto de aprendizaje y el de test sean independientes. Como norma general, en el caso de un universo de trabajo grande, la independencia queda asegurada si el conjunto de aprendizaje y el de test no tienen elementos en común. Esta independencia permite cierta confianza empírica en que el clasificador desarrollado posee la propiedad de *generalización*. Esta propiedad garantiza que un sistema clasifica correctamente patrones que no ha visto durante el proceso de cálculo de funciones discriminantes.

Si una vez contruidos los clasificadores se prueban, usando el conjunto de test, y se obtienen unos resultados deficientes, debe descartarse el conjunto de test y volver a comenzar de nuevo con un nuevo clasificador y nuevos conjuntos. Si para mejorar los resultados de test se volviese a realizar otro cálculo de las funciones discriminantes se estaría usando el conjunto de test de manera indirecta en el proceso de ajuste del clasificador. Para evitar esto, cuando hay suficiente muestra, suele crearse un tercer conjunto independiente de los otros dos, llamado *conjunto de validación*. Este conjunto se utiliza para probar el sistema mientras se está construyendo, por lo que éste sí se utiliza en el proceso de cálculo de las funciones discriminantes. El objetivo de este tercer conjunto es el de impedir que el conjunto de test se use más de una vez.

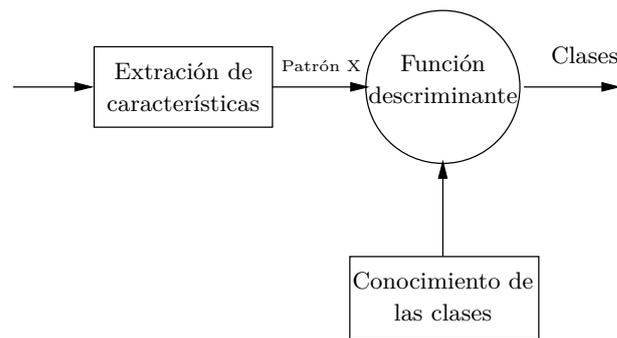


Figura 3.1: Esquema general de Sistema de Reconocimiento de Patrones.

Los clasificadores se pueden ordenar atendiendo a diferentes criterios: la forma de construirse, el tipo de muestra, la información disponible, etc. Atendiendo a la forma en que se construye un clasificador se dice que es de tipo *a priori* o *a posteriori*. *Los clasificadores a priori* construyen el clasificador en un solo paso, utilizando la muestra de aprendizaje para el cálculo de las funciones discriminantes y un cálculo exacto. *Los clasificadores a posteriori*, o con aprendizaje, se construyen siguiendo un procedimiento iterativo, o entrenamiento, en el cual el clasificador aprende a reconocer de una manera progresiva los patrones de la muestra de aprendizaje. Para ello suelen utilizar técnicas aproximadas (como el descenso de gradiente o el método de aproximación de Newton), lo que implica que el tiempo de aprendizaje puede no ser despreciable. Además, los clasificadores a posteriori normalmente precisan de un experto que decida el momento de detener el proceso de aprendizaje, ya que un entrenamiento excesivo puede perjudicar la propiedad de generalización que se persigue. Todo esto hace que la construcción de los clasificadores a posteriori sea más compleja que en el caso a priorístico. Sin embargo, los clasificadores a posteriori son la única opción en problemas en los no puede obtenerse una solución exacta debido a la complejidad de los cálculos que deberían realizarse para obtener dicha solución.

Atendiendo a la forma en que se distribuyen los patrones de la muestra se puede hablar de que se cumple o no la hipótesis determinista, es decir, si cada clase se puede representar por un único vector que se llama prototipo representante de la clase. Según esta hipótesis se puede hablar de dos tipos de clasificadores: *clasificadores determinísticos* y *clasificadores no determinísticos*. Dependiendo de las características seleccionadas puede ser necesario el uso de uno u otro tipo. Cuando las características elegidas hacen que los patrones de clases diferentes se sitúen en regiones disjuntas, los clasificadores determinísticos darán buenos resultados. Si las regiones no son disjuntas ofrecerán mejores resultados los clasificadores no determinísticos.

Según la información que se proporciona en el proceso de construcción del clasificador se puede hablar de dos tipos de clasificadores: *con maestro* o *supervisados*, y *sin maestro* o *no supervisados*. En los supervisados, la muestra la divide el maestro en las diferentes clases ya conocidas en las que se desea clasificar. A grandes rasgos, las etapas en la construcción de un clasificador con maestro son: determinación de las clases, elección y test de las características discriminantes, selección de la muestra, cálculo de funciones discriminantes y test del clasificador. En los no supervisados este proceso se realiza de manera automática, sin la necesidad de

ningún supervisor externo. Para ello se emplean técnicas de agrupamiento, gracias a las cuales el sistema selecciona y aprende los patrones que poseen características similares, determinándose automáticamente las clases.

Tradicionalmente, el reconocimiento de patrones se ha abordado desde un punto de vista estadístico, hablándose de reconocimiento estadístico de patrones (REP). Algunos se basan en el concepto de distancia entre los vectores de características como el *clasificador euclídeo*, el *clasificador de Mahalanobis*, o el *clasificador K-NN*. Otros son clasificadores de agrupamiento o *clustering*, también conocidos como clasificadores autoorganizados, como el *clasificador de distancias encadenadas*, el *clasificador MaxMin*, o el *clasificador K-Means*. Sin embargo, hay que decir que existen otros enfoques para el reconocimiento de patrones, de naturaleza no estadística. Así, por ejemplo, están aquéllos que utilizan redes de neuronas artificiales (ANN), o a los emplean sistemas de inferencia adaptativos neuro-borrosos (ANFIS). A estos nos referimos en este capítulo, al ser los utilizados en el desarrollo del trabajo objeto de esta Tesis Doctoral.

## 3.2 Reconocimiento de Patrones mediante Redes Neuronales Artificiales (ANN)

En los organismos más complejos existentes en la naturaleza, el sistema nervioso se encarga de recoger los impulsos del mundo circundante y de coordinar y dirigir todas las actividades de los órganos de acuerdo a lo que ha percibido de ese exterior. Este complejo sistema tiene como unidad funcional un único tipo de células: las *neuronas*. Las neuronas disponen de un elemento llamado *axón* que permite transmitir a otras neuronas, a través de las *dendritas*, impulsos eléctricos de diferente intensidad. Estas células se disponen en forma de complejas redes y mediante unos procesos, conocidos como *procesos sinápticos*, según los cuales se excitan o se inhiben unas a otras, son las responsables de las capacidades de aprendizaje y comprensión que caracterizan a los seres vivos que las poseen. En la figura 3.2 se muestra un esquema de un modelo biológico de conectividad entre dos células neuronales. El punto de contacto entre un *axón* de una célula y la *dendrita* de otra célula es lo que específicamente se denomina *sinapsis*.

Inspirándose en el funcionamiento de estas estructuras naturales surgen las redes de neuronales artificiales (ANN). Reproducir el sistema nervioso aún está lejos de nuestro alcance, pero aún así se han creado unos modelos que, aunque mucho más simples en su proceso que los modelos biológicos, se muestran extremadamente útiles en problemas de clasificación. Un tipo especial de red neuronal artificial que pese a su simplicidad se adecúa de manera notable a los problemas de reconocimiento de patrones, se conoce como *perceptrón*, y a él nos referimos más adelante en este capítulo.

El funcionamiento de las ANN tiene su base en la interacción de unos elementos de computación distribuida y estructura sencilla como son las neuronas, a través de un conjunto muy amplio de conexiones que tienen su origen en una de estas estructuras y su destino en otra. Estas conexiones tienen asociadas un valor real que determina la influencia de las mismas, y que se denomina *peso*. Como una misma

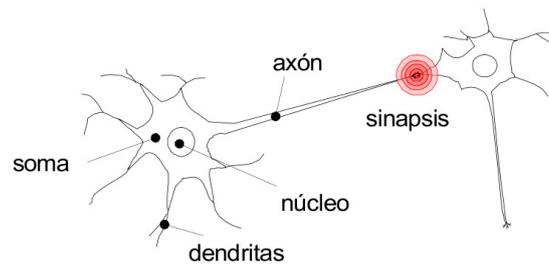


Figura 3.2: Modelo biológico de conexión entre dos neuronas

neurona puede ser destino de varias conexiones, las entradas que una neurona recibe se procesan mediante la *función de activación*, a partir de la cual se genera la salida de la neurona mediante la *función de salida*. Hay autores que denominan *función de transferencia* al conjunto formado por la función de activación y la función de salida.

Se pueden distinguir tres tipos principales de neuronas artificiales. Las *neuronas de entrada* son aquéllas por donde se introducen los datos, a partir de los cuales la red producirá la respuesta. Son las únicas neuronas cuyo estado de activación se impone directamente desde el exterior. Las *neuronas de salida* son las que con su estado de activación definen la respuesta de la red ante el estímulo suministrado a su entrada. Puede haber, por último, una serie de neuronas intermedias, llamadas *neuronas ocultas*, que procesan y propagan información desde la entrada hasta la salida.

### 3.2.1 Modelo de Neurona

La figura 3.3 muestra el diagrama de bloques de una neurona con entrada simple. La entrada individual, el escalar ( $p$ ), se pondera multiplicándola por el escalar *peso* ( $w$ ). La otra entrada (1), cuya misión es proporcionar un desplazamiento positivo a la entrada ponderada (*bias*) se multiplica por una ganancia ( $b$ ) y la suma de ambos términos pasa al integrador. Esta suma constituye la entrada ( $n$ ) a la función de transferencia ( $f$ ), la cual produce la salida de la neurona ( $a$ ).

$$\begin{aligned} n &= w \cdot p + b \\ a &= f(n) = f(w \cdot p + b) \end{aligned} \quad (3.1)$$

Si relacionamos este modelo simple de neurona con el modelo biológico descrito anteriormente, la entrada ( $p$ ) representa la señal que proviene de otra neurona y que es capturada por la dentrita, el *peso* ( $w$ ) se relaciona con la intensidad de una *sinápsis*, el núcleo de la célula está representado por el sumatorio y la función de transferencia ( $f$ ), y la salida ( $a$ ) de la neurona representa la señal en el *axón*.

Habitualmente una neurona tiene más de una entrada. Una neurona con  $R$  entradas se muestra en la figura 3.4. Cada vector de entrada ( $p_1, p_2, \dots, p_R$ ) se pondera multiplicándolo por el vector de pesos ( $w_{1,1}, w_{1,2}, \dots, w_{1,R}$ ). La suma de las entradas ponderadas y las ganancias ( $b$ ) componen la entrada ( $n$ ) a la función de transferencia ( $f$ ).

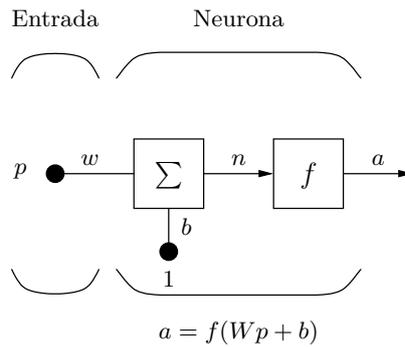


Figura 3.3: Modelo de neurona con entrada única

$$n = w_{1,1} \cdot p_1 + w_{1,2} \cdot p_2 + \dots, w_{1,R} \cdot p_R + b \quad (3.2)$$

Esta expresión puede escribirse en forma compacta:

$$n = \mathbf{w} \cdot \mathbf{p} + b \quad (3.3)$$

Cuando se trate de una red de neuronas, y no de una sola, tendremos una matriz de pesos (no un vector). Los subíndices de los elementos de esta matriz denotan los componentes indicados en la conexión; el primer subíndice representa la neurona destino (en este caso única) y el segundo representa la entrada que alimenta a la neurona.

De esta forma, la salida de la neurona ( $a$ ) puede expresarse como

$$a = f(\mathbf{w} \cdot \mathbf{p} + b) \quad (3.4)$$

La salida depende de la función de transferencia que se utilice. Estas pueden ser funciones lineales o no-lineales de ( $n$ ) y se eligen para satisfacer alguna especificación del problema que la neurona pretende resolver.

Las entradas a una neurona artificial ( $p_1, p_2, \dots, p_R$ ) son funciones continuas, en lugar de los pulsos discretos correspondientes a las neuronas biológicas. El papel que desempeñan los pesos en una neurona artificial es análogo al de la función sináptica de la neurona biológica, pudiendo dichos pesos ser positivos (excitadores) o negativos (inhibidores). Acumuladas las entradas ponderadas en el nodo sumatorio, es la función de transferencia la encargada de generar la salida según el resultado de este sumatorio. Existen una gran variedad de funciones de transferencia, y a continuación revisaremos tres de ellas, que son las más comúnmente utilizadas.

### Funciones de Transferencia

La función de transferencia *Escalón* también conocida como *limitador fuerte* (*hard-lim*), se muestra en el lado izquierdo de la figura 3.5. La salida de la neurona será 0 si el argumento de la función es menor que 0, o 1 si su argumento es mayor o igual que 0. Esta función de transferencia se utiliza para crear neuronas que clasifiquen entradas en dos categorías distintas. El gráfico de la derecha de la figura 3.5 ilustra

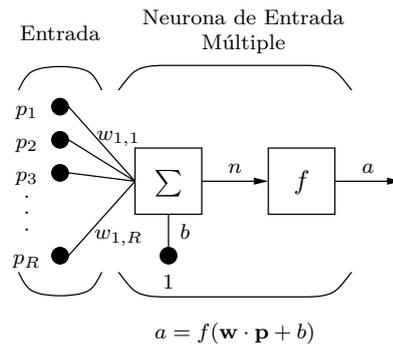


Figura 3.4: Modelo de neurona de entrada múltiple

las características de la entrada/salida de una neurona de entrada simple que utiliza una función de transferencia *Escalón*, en donde se puede apreciar el efecto de los pesos ( $w$ ) y las ganancias ( $b$ ). Entre los dos gráficos de la figura se muestra el icono que representa esta función y que reemplaza al genérico ( $f$ ) utilizado en los diagramas de redes.

$$a = \begin{cases} 1 & \text{si } n \geq 0 \\ 0 & \text{si } n \leq 0 \end{cases} \quad (3.5)$$

Una modificación de esta función también muy utilizada consiste en adoptar como valores discretos del espacio de salida los valores 1 y  $-1$ .

$$a = \begin{cases} 1 & \text{si } n \geq 0 \\ -1 & \text{si } n \leq 0 \end{cases} \quad (3.6)$$

Una segunda función de transferencia es la *Lineal* o *Identidad* en la que la salida es igual a su entrada  $a = n$ , tal y como se aprecia a la izquierda de la figura 3.6. El gráfico de la derecha de esta figura ilustra las características de la entrada/salida de una neurona de entrada simple que utiliza una función de transferencia *Lineal* y en donde se puede apreciar el efecto de los pesos y los niveles. Entre los dos gráficos de la figura se muestra el icono que representa esta función. Neuronas con este tipo de función de transferencia son utilizadas en un tipo de redes conocidas como *Adaptive Linear Neuron* o ADALINE.

Finalmente, otra de las funciones de transferencia más comúnmente utilizadas es la *Logarítmica-Sigmoidal* que se muestra en la parte izquierda de la figura 3.7. Esta función de transferencia toma la entrada (que puede tener cualquier valor comprendido entre  $+\infty$  y  $-\infty$ ) y amolda la salida al rango 0–1 de acuerdo con la expresión:

$$a = \frac{1}{1 + e^{-n}} \quad (3.7)$$

El gráfico de la derecha de la figura 3.7 ilustra las características de la entrada/salida de una neurona de entrada simple que utiliza una función de transferencia

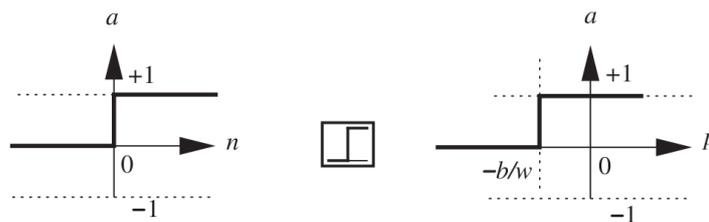


Figura 3.5: Función de transferencia Escalón.

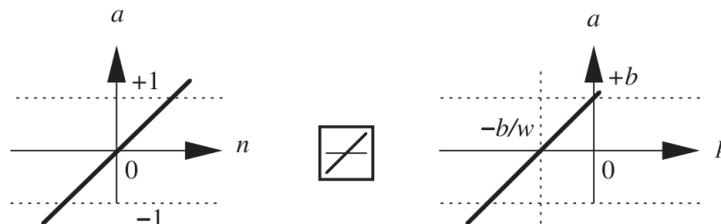


Figura 3.6: Función de transferencia Lineal.

*Logarítmica-sigmoidal* y en donde de nuevo se puede apreciar el efecto de los pesos y los niveles. Entre los dos gráficos de la figura se muestra el icono que representa esta función.

### 3.2.2 Topología de una Red

En una red neuronal los elementos de procesamiento se encuentran agrupados por capas. Una capa es una colección de neuronas que, de acuerdo a su ubicación dentro de la red, recibe diferentes nombres: capa de entrada, que recibe las señales de la entrada de la red y que algunos autores no consideran como una capa pues allí no se lleva a cabo ningún proceso; capas ocultas, que no tienen contacto con el medio exterior y son las que determinan las diferentes topologías de la red; y la capa de salida que recibe la información y la transmite al medio externo.

Una red de una sola capa con un número  $S$  de neuronas se muestra a la izquierda en la figura 3.8, en la cual cada una de las  $R$  entradas es conectada a cada una de las neuronas y la matriz de pesos tiene  $S$  filas. La capa incluye la matriz de pesos, los sumadores, el vector de ganancias ( $\mathbf{b}$ ), las funciones de transferencias y el vector de salida ( $\mathbf{a}$ ). Es habitual que el número de entradas a la red sea diferente al número de neuronas ( $R \neq S$ ).

Esta misma red se representa en notación abreviada en la misma figura a la derecha, en donde se han dispuesto los símbolos de las variables de tal manera que describen las características de cada una de ellas. Por ejemplo, la entrada a la red es el vector  $\mathbf{p}$  de longitud  $R$ , la matriz de pesos ( $\mathbf{W}$ ) tiene de dimensiones  $S \times R$ , y  $\mathbf{a}$  y  $\mathbf{b}$  son vectores de longitud  $S$ .

Si se considera una red de con varias capas, o red multicapa, cada capa tendrá su propia matriz de pesos ( $\mathbf{W}$ ), su propio vector de ganancias ( $\mathbf{b}$ ), un vector de

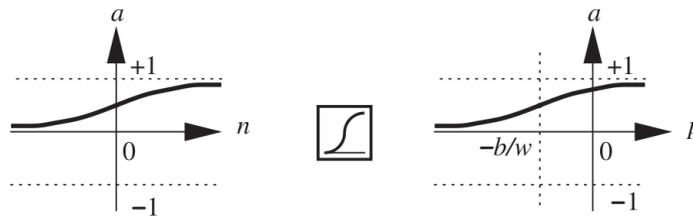


Figura 3.7: Función de transferencia Logarítmica-sigmoidal.

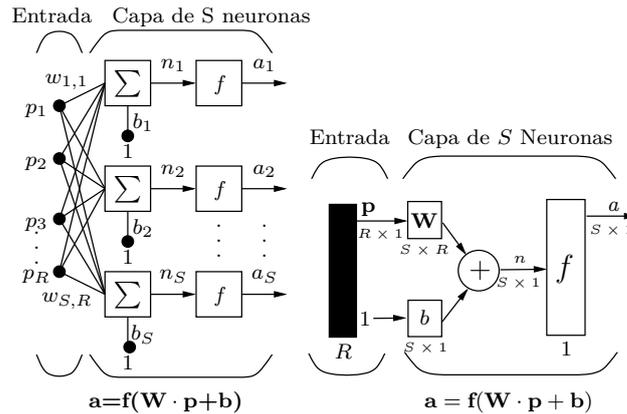


Figura 3.8: ANN con una capa de  $S$  neuronas.

entradas netas ( $\mathbf{n}$ ), y un vector de salida ( $\mathbf{a}$ ). Las figuras 3.9 y 3.10 ilustran la versión completa y en notación abreviada de una red de tres capas con  $R$  entradas,  $S^1$  neuronas en la primera capa,  $S^2$  neuronas en la segunda capa y en donde las salidas de las capas (1) y (2) son las entradas a las capas (2) y (3) respectivamente. Así, la capa (2) puede ser vista como una red de una capa con  $R = S^1$  entradas,  $S^1 = S^2$  neuronas y una matriz de pesos  $\mathbf{W}^2$  de dimensiones  $S^1 \times S^2$ .

A la capa cuya salida es a su vez la salida de la red se le llama capa de salida. A las otras capas se les llama capas ocultas. La red mostrada en las figuras 3.9 y 3.10 consta de una capa de salida (tercera capa) y dos capas ocultas (capas primera y segunda).

### 3.2.3 El Proceso de Aprendizaje

El cálculo de los pesos que deben poseer las conexiones de una ANN para que realice la función que se desea se conoce como *aprendizaje*. En redes triviales el ajuste de estos pesos se puede hacer manualmente, pero la tarea se vuelve mucho más ardua en redes de una complejidad mínima. Se han inventado diferentes algoritmos que realizan esta tarea de manera más o menos automática sobre distintos tipos de redes.

Desde un punto de vista puramente matemático, dejando de lado lo que las entradas o las salidas de la red significan en este contexto, el problema consiste

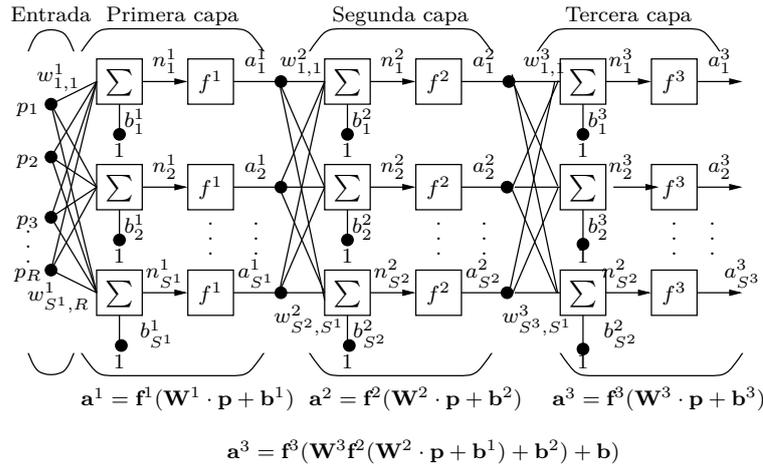


Figura 3.9: ANN con tres capas.

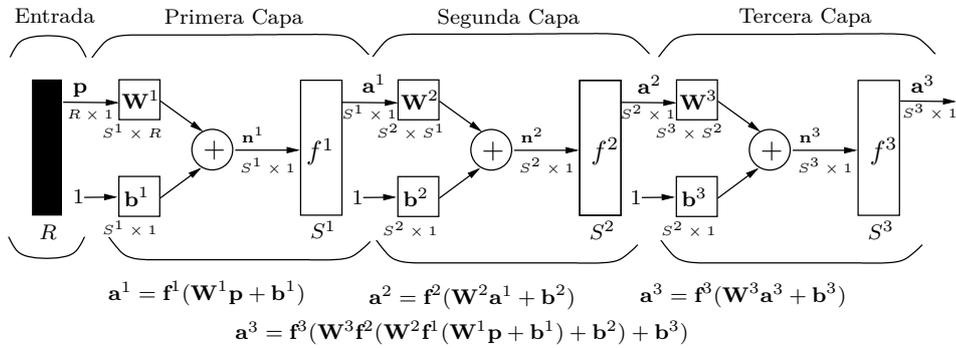


Figura 3.10: ANN con tres capas. (Notación abreviada).

en encontrar el valor de unas incógnitas (los pesos) para que unas funciones (las ecuaciones de las neuronas) obtengan ciertos valores (la salida deseada) cuando se dan unos valores determinados a sus parámetros (las entradas a la red). En caso de no poder obtenerse exactamente el valor buscado se podría pensar en minimizar el error entre la salida deseada y la obtenida. Esto lleva al problema de encontrar el mínimo global de una función arbitraria, problema para el que en general no se conoce solución. Son aplicables sin embargo una infinidad de procedimientos numéricos, basados generalmente en métodos del gradiente, que desgraciadamente sólo permiten obtener soluciones locales a este problema. El algoritmo más popular es el de aprendizaje por *retropropagación* (*backpropagation*).

### Generalización de las ANN

Durante el entrenamiento, las salidas de una red de neuronas se aproximan a ciertos valores objetivo. Esto puede bastar para ciertas aplicaciones, pero la aplicabilidad de las ANN se debe en gran medida su capacidad para generalizar. Se entiende por generalización a la propiedad que les permite generar salidas adecuadas frente a entradas que no se encuentran en el conjunto de entrenamiento, y que por tanto la

red no ha aprendido previamente. La generalización no siempre es posible, siendo necesarias tres condiciones para que pueda conseguirse la generalización:

- Que las entradas contengan suficiente información para que se puedan alcanzar las salidas deseadas al menos en el entrenamiento. Si la red no es capaz de aprender algo, difícilmente será capaz de generalizar posteriormente.
- Que la función a interpolar sea, en cierto sentido, suave. Es decir, que un pequeño cambio en la entrada debe producir un pequeño cambio en la salida. Esto comporta que la función que se aproxima con la ANN sea continua hasta la primera derivada. Por ello las salidas de funciones como los generadores de números pseudo-aleatorios o algoritmos como los de encriptación no pueden ser emuladas con una red neuronal.
- Que el conjunto de entrenamiento sea suficientemente grande. Esto se debe a que la generalización se produce en dos sentidos: interpolando y extrapolando. La interpolación en general da buenos resultados, pero la extrapolación no, razón por la que se deben tener suficientes casos de entrenamiento como para evitar la extrapolación.

#### Conjuntos para Entrenar una Red

Para el ajuste de los pesos de las ANN, se precisan unos patrones con las entradas a la red y otros con las salidas deseadas frente a esas entradas, constituyendo lo que se llama *conjunto de entrenamiento* (CE). Se usará este conjunto para entrenar la red, mediante un procedimiento iterativo, consistente en variar los pesos buscando minimizar la función de error que se haya determinado.

Clásicamente se distingue otro conjunto, denominado *conjunto de test del entrenamiento* (CTE), que se usa para saber en qué momento se debe detener el entrenamiento. Una red sobre-entrenada ha memorizado demasiado, y es incapaz de generalizar a nuevos patrones distintos a los del entrenamiento. O de otra forma, un *sobre-entrenamiento* hace que la red ajuste los pesos en exceso, curvando mucho, para ello, la superficie formada por los pesos, de manera que entradas próximas, pero no iguales obtienen resultados muy diferentes; con un entrenamiento menos exhaustivo las entradas próximas darían resultados similares, pues la superficie formada por los pesos es más suave y se produce un proceso de interpolación. *El punto de generalización óptimo* sería aquel a partir del cual la red memoriza en demasía, y antes del cual la red puede mejorar sus resultados con los conjuntos CTE y CE. La figura 3.11 ilustra el punto de generalización óptimo en términos de la cantidad de entrenamiento y los errores producidos.

Una vez terminado el entrenamiento se debe disponer de un tercer conjunto, llamado *conjunto de validación* (CV), con el que se evalúa la red. Es importante que CV se use sólo como comprobación final, pero nunca para entrenar la red. Si no, la red aprenderá este conjunto también, y no se sabrá si es capaz de generalizar.

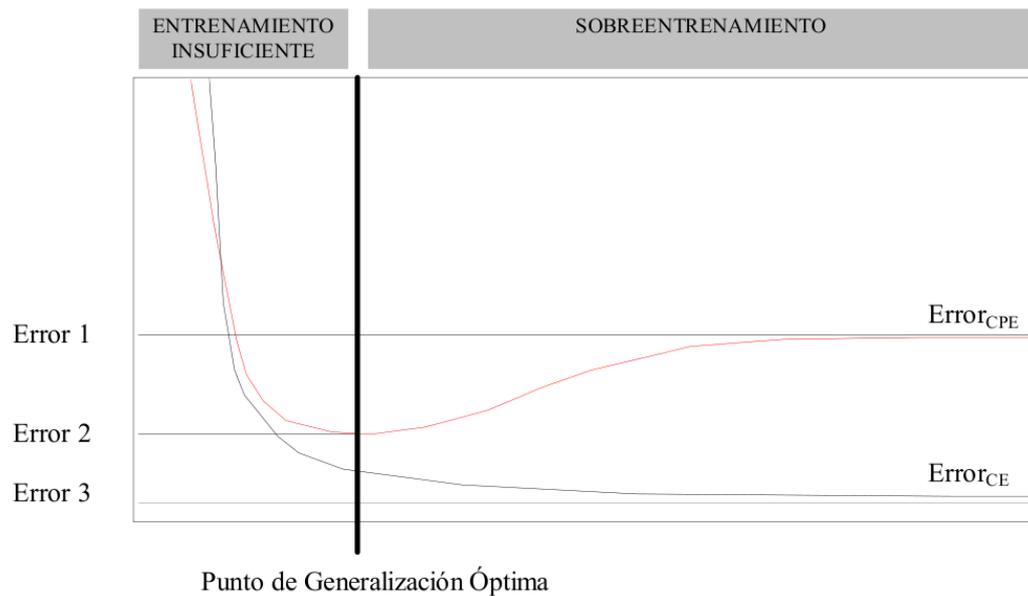


Figura 3.11: Proceso de entrenamiento.

### 3.2.4 Perceptrón

La red *perceptrón* fue inventada por el psicólogo Frank Rosenblatt en el año 1958. Su intención era ilustrar algunas propiedades fundamentales de los sistemas inteligentes en general, sin entrar en mayores detalles con respecto a condiciones específicas y desconocidas para organismos biológicos concretos. A partir de un modelo de neurona artificial como el que se muestra en la figura 3.12, ya sea con una única entrada o con entradas múltiples, se puede definir una red compuesta por varias de estas unidades que operan de forma independiente, es decir, que la salida de cualquiera de ellas no influye en el funcionamiento del resto. Esta configuración, conocida como *perceptrón* de una sola capa, o simplemente perceptrón, equivale a varios clasificadores euclídeos.

En la estructura general del perceptrón podemos variar tanto el número de neuronas como el número de capas de la red. En la figura 3.13 se representa gráficamente una de estas estructuras. En este caso se trata de una red de una sola capa de  $S$  neuronas, en donde cada una de las  $R$  entradas están conectadas con cada una de las neuronas y donde los pesos forman una matriz de  $S$  filas. La capa incluye los pesos que definen la conexión entre los componentes del vector de entrada y cada neurona ( $w_{i,j}$ ), los sumadores, los niveles ( $b_S$ ), las funciones de transferencia y el vector de salida ( $\mathbf{a}$ ). Algunos autores consideran las entradas como otra capa de la red.

El perceptrón multicapa es una red compuesta por varios niveles sucesivos de perceptrones de una sola capa, como la de la figura 3.14, de manera que las salidas de las unidades de una capa suponen las entradas de las unidades del nivel siguiente.

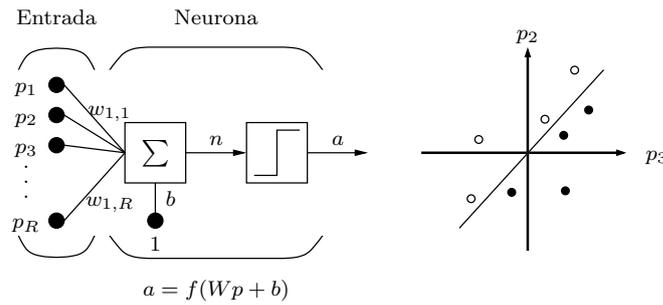


Figura 3.12: Diagrama de bloques del Perceptrón.

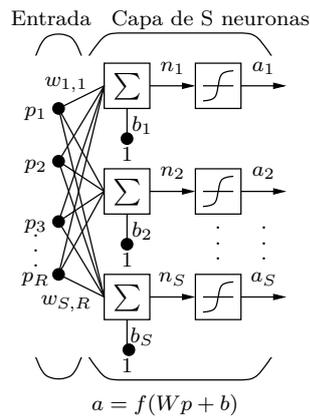


Figura 3.13: Perceptrón de una capa de  $S$  neuronas.

Cada capa tiene sus propios pesos ( $\mathbf{W}$ ), sus propios niveles ( $\mathbf{b}$ ), un vector de entrada ( $\mathbf{p}$ ) y un vector de salida ( $\mathbf{a}$ ). En la red mostrada en la figura 3.14 hay  $R$  entradas,  $S^1$  neuronas en la primera capa,  $S^2$  neuronas en la segunda capa y  $S^3$  neuronas en la tercera capa. La tercera capa sería la capa de salida, mientras que las capas primera y segunda se denominan capas ocultas.

El perceptrón multicapa tiene una serie de propiedades que lo hacen especialmente interesante al usarlo como clasificador:

- Robustez frente al ruido aleatorio, lo que conlleva la selección automática de las características importantes dentro del vector de características que se introduce a la red.
- Separación de regiones complejas dependiendo de la estructura de la red. Una red puede separar clases a pesar de que la hipersuperficie de separación entre ambas sea arbitrariamente compleja, o incluso no sea única.
- Capacidad de generalización. Los algoritmos de descenso del gradiente han demostrado en la práctica que obtienen buenas interpolaciones para patrones con los que no se ha entrenado el sistema.

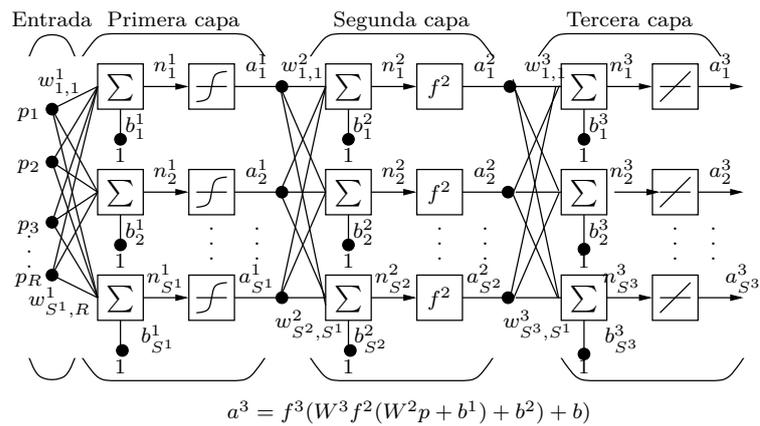


Figura 3.14: Perceptrón de tres capas.

### Selección del número de capas ocultas

Ya se ha comentado que una red con una sola capa de neuronas y sin unidades ocultas equivale a varios clasificadores euclídeos, uno por cada neurona, siendo capaz de discriminar mediante hiperplanos conjuntos de patrones linealmente separables. Para poder discriminar dos conjuntos sea cual sea la disposición de sus patrones se puede utilizar una red con una sola capa oculta. En los siguientes párrafos trataremos de justificar esta afirmación.

En primer lugar hay que constatar que siempre es posible agrupar los patrones de cualquier clase formando subconjuntos convexos. Estos subconjuntos convexos tienen la particularidad de que pueden separarse linealmente del resto de elementos mediante varios hiperplanos. En la figura 3.15 se representa un patrón interior a un subconjunto convexo que queda clasificado por la intersección de las regiones definidas por varios hiperplanos.

Es fácil demostrar que este primer paso de separación mediante hiperplanos se puede resolver con una red perceptrón sin unidades ocultas, con una neurona de salida por hiperplano necesario. Cuando, ante un patrón, todas las neuronas de salida de una de estas intersecciones se activan simultáneamente indica que ese patrón pertenece a ese subconjunto convexo.

El siguiente paso consiste en la unión de los resultados de estos subconjuntos convexos en las clases que les dieron origen. Se puede demostrar que esta tarea la puede realizar una red perceptrón, sin unidades ocultas y con una neurona de salida por cada clase a discriminar. En particular, una neurona de salida, correspondiente a una clase  $C$ , tendrá un umbral  $H$ . Para que esta neurona se active sólo cuando un patrón corresponda a la clase  $C$ , el umbral  $H$  puede tomarse ligeramente menor al número de hiperplanos necesarios para separar cada uno de los subconjuntos convexos de la clase  $C$ .

Por tanto, concatenando las dos redes descritas, es decir, construyendo una red con una capa oculta y tantas neuronas de salida como clases, se pueden separar regiones con forma cualquiera.

Así, al menos teóricamente, el comportamiento de cualquier red de dos o más

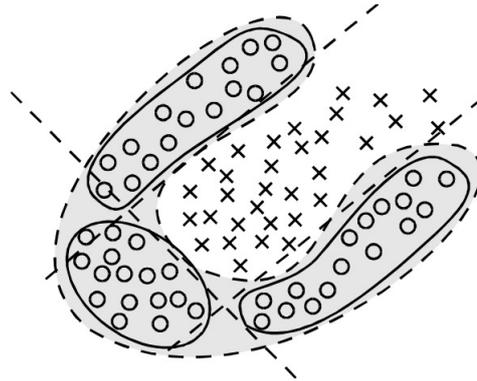


Figura 3.15: Patrones de una muestra agrupados en regiones convexas.

capas se puede obtener con una red de sólo una capa oculta. Sin embargo, los algoritmos de aprendizaje que se conocen no garantizan que esta búsqueda tenga éxito. Es más, la mayoría de las veces estos algoritmos ofrecen buenos resultados cuando se disponen varias capas ocultas, y malos resultados cuando sólo se dispone una capa oculta.

### 3.2.5 Algoritmos de Aprendizaje para el Perceptrón Multicapa

El perceptrón es un tipo de red de aprendizaje supervisado, es decir necesita conocer los valores esperados para cada de las entradas presentadas. Cualquier algoritmo dirigido al ajuste de los pesos de una ANN debe minimizar alguna función que esté relacionada con el error cometido en las unidades de salida al presentarle una entrada. Si para cada configuración posible de los pesos de una red se conoce el error que comete a la salida al presentarle una entrada determinada, el error puede verse como una superficie cuya altura depende de las coordenadas de los pesos.

La búsqueda del mínimo de estas superficies ha dado lugar a varios algoritmos basados en su mayoría en métodos de descenso del gradiente. Entre todos destaca, por su simplicidad y buenos resultados, el algoritmo de *retropropagación del gradiente* (*backpropagation*), ideado en 1974 por Werbos y redescubierto de manera independiente en 1985 por Le Cun y Parker. En la base del algoritmo de *retropropagación del gradiente* está la regla delta que a continuación se pasa a explicar.

#### Regla Delta

Para el perceptrón existe un algoritmo, conocido como regla delta o algoritmo LMS (*Least Minimum Squares*), que cambia los pesos en la dirección de máxima pendiente dentro de la superficie del error. Las diferentes componentes del vector de dirección de máxima pendiente vienen determinadas por las derivadas parciales según cada componente de la función error:

$$\Delta w_{ij} = -\mu \cdot \frac{\partial \varepsilon}{\partial w_{ij}} \quad (3.8)$$

En la ecuación anterior se aprecia que se ha añadido un término ( $\mu$ ) cuya función es determinar la velocidad de variación de los pesos ( $w_{ij}$ ), término que se conoce como *tasa de aprendizaje*. Un valor de ( $\mu$ ) pequeño puede hacer que se caiga fácilmente en mínimos locales, mientras que un valor de  $\mu$  grande puede hacer que se esté siempre oscilando, sin converger nunca. Desgraciadamente el concepto de grande y pequeño varía según la superficie de error que se esté considerando, que a priori es desconocida ya que depende de la muestra que se use para el entrenamiento, por lo que su ajuste constituye un proceso experimental.

De la ecuación (3.8) se deduce que se debe disponer de una medida para el error. La medida más común de éste consiste en la suma de las diferencias cuadráticas entre los valores obtenidos ( $a_s$ ) y los deseados ( $t_s$ ) en las neuronas de salida, después de presentar cada patrón de entrenamiento. Esta medida se conoce como *error cuadrático medio*, y se define como:

$$\varepsilon = \frac{1}{S} \sum_{s=1}^S (a_s - t_s)^2 \quad (3.9)$$

donde  $S$  es el número total de neuronas de salida y se ha tomado la salida de una neurona  $j$  como una función  $f$  de la entrada total a la misma, de acuerdo con la función de activación y función de salida:

$$a_j = f(n_j) \quad (3.10)$$

Si se aplica sobre la ecuación (3.9) la derivada de la función compuesta, se puede escribir:

$$\frac{\partial \varepsilon}{\partial w_{ij}} = \frac{\partial \varepsilon}{\partial n_j} \cdot \frac{\partial n_j}{\partial w_{ij}} \quad (3.11)$$

Teniendo en cuenta que  $n_j = \sum_i a_i \cdot w_{ij}$ , se puede deducir:

$$\frac{\partial n_j}{\partial w_{ij}} = a_i \quad (3.12)$$

Definimos ahora el cambio del peso ( $\delta$ ):

$$\delta_j = -\frac{\partial \varepsilon}{\partial n_j} \quad (3.13)$$

De esta manera, uniendo las expresiones (3.12) y (3.13) se puede reescribir la expresión (3.8), que determina la variación de los pesos en su búsqueda del mínimo, como:

$$\Delta w_{ij} = \mu \cdot \delta_j \cdot a_j \quad (3.14)$$

El parámetro  $\delta_j$  se obtiene aplicando de nuevo la derivada de la función compuesta:

$$\delta_j = -\frac{\partial \varepsilon}{\partial n_j} = -\frac{\partial \varepsilon}{\partial a_j} \cdot \frac{\partial a_j}{\partial n_j} \quad (3.15)$$

El segundo término de esta ecuación equivale a derivar respecto de  $n_j$  la ecuación (3.10):

$$\frac{\partial a_j}{\partial n_j} = f'(n_j) \quad (3.16)$$

Si la neurona  $j$  es una neurona de salida, en la ecuación (3.9) uno de los términos considerados será la misma neurona. En tal caso el primer término de la ecuación (3.15) puede calcularse directamente derivando (3.9) respecto de  $a_j$ . Consecuentemente, la aplicación de esta fórmula para el error se realiza sólo en los casos en que la función de activación de las neuronas es continua y derivable:

$$-\frac{\partial \varepsilon}{\partial a_j} = (t_j - a_j) \quad (3.17)$$

$$\delta_j = (t_j - a_j) \cdot f'(n_j) \quad (3.18)$$

Como se desprende de la ecuación (3.18), la aplicación de la regla delta depende de la derivada de la función de activación. La función de activación más común es la sigmoide, pero también suelen usarse la función tangente hiperbólica y la función identidad.

Si la función es la sigmoide se puede escribir:

$$a_j = f(n_j) = \frac{1}{1 + e^{-n_j}} \Rightarrow e^{-n_j} = \frac{1}{a_j} - 1 \quad (3.19)$$

Derivando:

$$f'(n_j) = \frac{1}{1 + e^{-n_j}} = \frac{e^{-n_j}}{(1 + e^{-n_j})^2} = a_j \cdot (1 - a_j) \quad (3.20)$$

### La Red *Backpropagation* (BPN)

En 1986, Rumelhart, Hinton y Williams formalizaron un método para que una red neuronal aprendiera la asociación que existe entre los patrones de entrada y las clases correspondientes, utilizando varios niveles de neuronas.

El método de propagación del error hacia atrás o *backpropagation*, basado en la generalización de la regla delta, a pesar de sus limitaciones ha ampliado de forma considerable el rango de aplicaciones de las redes neuronales.

El funcionamiento de la *red backpropagation* (BPN) consiste en el aprendizaje de un conjunto predefinido de pares de entradas-salidas dados como ejemplo: primero se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red, se va propagando a través de todas las capas superiores hasta generar una salida, se compara el resultado en las neuronas de salida con la salida que se desea obtener y se calcula un valor de error para cada neurona de salida. A continuación, éstos errores se transmiten hacia atrás, partiendo de la capa de salida hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida, recibiendo de error aproximado a la neurona intermedia a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total. Basándose en el valor del

error recibido, se reajustan los pesos de conexión de cada neurona, de manera que en la siguiente vez que se presente el mismo patrón la salida se acerque más a la deseada.

La importancia de la red *backpropagation* consiste en su capacidad de auto-adaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe ente un conjunto de patrones de entrada y sus salidas correspondientes. Es importante la capacidad de generalización, que recordamos es la facilidad de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento; la red debe encontrar una representación interna que le permita generar las salidas deseadas cuando se le dan entradas de entrenamiento, y que pueda aplicar, además, a entradas no presentadas durante la etapa de aprendizaje para clasificarlas.

El algoritmo de *backpropagation* supone, como ya se ha indicado, una generalización de la *regla delta*, de manera que pueda aplicarse a perceptrones multicapa. En estas redes las ecuaciones (3.18) y (3.20) permiten el cálculo del incremento de los pesos para las neuronas de la última capa. Sin embargo, en las neuronas intermedias no se conoce el valor deseado para su salida, por lo que estas fórmulas no se pueden aplicar directamente.

La idea central de la retropropagación está en que el valor deseado para una neurona de una capa intermedia  $J$  (figura 3.16) puede deducirse del valor deseado para las neuronas de la siguiente capa  $K$ . La aplicación de esta idea de manera recursiva nos conducirá a la última capa para la que sí se conoce el valor deseado a la salida.

En un perceptrón multicapa, el error cometido por la red se puede describir como una función  $\psi$  de las entradas a cualquier capa intermedia de la red, sin más que ir sustituyendo en la ecuación (3.9) los términos salida por sus correspondientes de la ecuación (3.10). Así, para un nivel  $J$  cualquiera en el que se encuentran las neuronas  $(1, 2, \dots, j, \dots, J)$ , se puede expresar el error en función de las entradas a este nivel de la siguiente manera:

$$\varepsilon = \psi(n_1, n_2, \dots, n_j, \dots, n_J) \quad (3.21)$$

Teniendo en cuenta la definición previa y usando la derivada de la función compuesta, se puede simplificar el primer término de la ecuación (3.15) para cualquier neurona de la red.

$$\begin{aligned} -\frac{\partial \varepsilon}{\partial a_j} &= -\sum_{k=1}^K \frac{\partial \varepsilon}{\partial n_k} \cdot \frac{\partial n_k}{\partial a_j} = \\ &= -\sum_{k=1}^K \frac{\partial \varepsilon}{\partial n_k} \cdot \frac{\partial \left( \sum_{j=1}^J w_{jk} a_j \right)}{\partial a_j} \end{aligned} \quad (3.22)$$

Realizando la derivada y usando el resultado de la ecuación (3.15) se llega a:

$$-\sum_{k=1}^K \frac{\partial \varepsilon}{\partial n_k} \cdot w_{jk} = \sum_{k=1}^K \delta_k \cdot w_{jk} \quad (3.23)$$

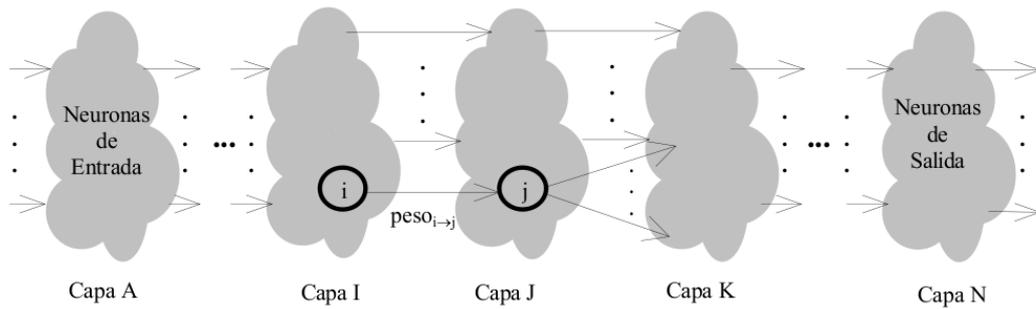


Figura 3.16: Esquema general de una conexión entre neuronas en un perceptrón multicapa.

Sustituyendo esta ecuación y la (3.16) en la ecuación (3.15) se obtiene:

$$\delta_j = \dot{f}'(n_j) \cdot \sum_{k=1}^K \delta_k \cdot w_{jk} \quad (3.24)$$

Esta última expresión nos permite conocer el valor de cambio para una capa siempre que se conozca el valor correspondiente de la capa siguiente. Este proceso tiene fin en la última capa de la que se conoce el valor de cambio gracias a la ecuación (3.18). Constituye por tanto un método constructivo para ir calculando el incremento de los pesos que minimiza el error según la ecuación (3.9), y que exige que la función de activación de cada neurona sea derivable respecto de la entrada a la misma.

### 3.3 Lógica Borrosa y Reconocimiento de Patrones mediante ANFIS

En cualquier desarrollo en ingeniería es fundamental el análisis de la información y el conocimiento de la incertidumbre e imprecisión asociada con los fenómenos reales y con la percepción, interpretación y modelado de la realidad. El adecuado tratamiento y modelado de la incertidumbre conduce a sistemas de ingeniería confiables, económicos y seguros.

No existe, prácticamente, ningún problema de ingeniería en donde se tenga la información total sobre todas las variables y en donde esta información no tenga ningún grado de incertidumbre o imprecisión. Un problema de ingeniería con todos los datos y completamente determinístico no es un problema real.

La principal dificultad en el tratamiento o modelado de la incertidumbre recae precisamente en su propia naturaleza. Todo intento de determinar sus características se traduce en reducir el nivel de incertidumbre. En general, se manejan situaciones en las cuales se cuenta con diferentes tipos o niveles de incertidumbre.

Tradicionalmente, la incertidumbre ha sido modelada a través de la teoría de la probabilidad. Sin embargo, debido a que la incertidumbre no es igual en todos los casos, se han formulado otras formas de manejar la incertidumbre de las variables, tales como la teoría de las posibilidades, la lógica borrosa y la teoría de Dempster-Shafer, entre otras.

Por otra parte, en los problemas de la vida real se utiliza la información inmediata (datos, experiencia, razonamientos a priori) para hacer inferencias que conduzcan a algo más amplio que no se observa directamente. A través de la inferencia se utilizan observaciones del mundo para revelar otros hechos que no se han observado, o se pueden conocer efectos causales a partir de los datos observados. En un sentido amplio, la inferencia va desde la simple implicación hasta el proceso mental operativo mediante el cual, partiendo de determinada información, se llega por cualquier mecanismo lógico a una conclusión.

Bajo incertidumbre, la inferencia utiliza diferentes técnicas para el tratamiento de las características inciertas. De esta manera, es importante diferenciar el tipo de incertidumbre que se está tratando para determinar la técnica más conveniente a utilizar.

#### 3.3.1 Taxonomía de la Incertidumbre

En un problema dado, en general, es posible encontrar incertidumbre en distintos grados. De menor a mayor podemos enumerar los siguientes grados: el determinismo, la aleatoriedad, la ambigüedad o no especificidad, la vaguedad y por último la confusión.

Comenzando con el menor grado de incertidumbre, el determinismo corresponde con el conocimiento perfecto de los resultados y de la ocurrencia de los eventos. Por tanto el determinismo es la no existencia o consideración de incertidumbre.

Aumentando el grado de incertidumbre, la aleatoriedad se presenta cuando los posibles eventos resultantes de un experimento son conocidos; por ejemplo, es el caso del lanzamiento de un dado o de una moneda. También aparece en situaciones de conflicto, como en el caso de una afirmación que puede ser verdadera o falsa. Este tipo de incertidumbre se ha modelado con la teoría de las probabilidades.

La ambigüedad proviene de la existencia de diferentes significados de una palabra o de una expresión. En este caso los eventos no están especificados o definidos claramente. Corresponde a la falta de información y se da cuando existe una relación de uno a muchos.

La vaguedad hace imposible establecer la verdad o falsedad de una afirmación. La vaguedad difiere en general de la ambigüedad en que esta última envuelve diferentes significados incompatibles y puede resolverse con mayor información. Una mayor cantidad de información no ayuda en general a resolver el problema de vaguedad como sí sucede en el caso de la ambigüedad.

Por último la confusión es un tipo de incertidumbre de conflicto, que reúne características tanto ambiguas como vagas.

Cuando la incertidumbre es de tipo aleatorio, es posible en muchos casos modelar los problemas de incertidumbre asignando probabilidades a los distintos eventos a través de la frecuencia relativa y el análisis estadístico. Estos posibles resultados están claramente definidos y de esta manera es posible obtener una medida muy concreta de la probabilidad de que esos eventos ocurran.

Sin embargo, si esto no es posible, desde el punto subjetivista la probabilidad puede ser considerada como una medida personal de la incertidumbre o de creencia sobre un evento o un objeto y la probabilidad no existe como algo concretamente definido. Esto permite modelar algunos problemas en los cuales no se tienen datos

estadísticos sobre la ocurrencia de ciertos eventos (por ejemplo cuando es imposible repetir un experimento en varias ocasiones), pero su probabilidad puede ser asignada con base en la creencia de las personas sobre esa ocurrencia [46].

Algunos autores afirman que cualquier tipo de incertidumbre puede ser tratado con la teoría de la probabilidad, reduciendo las características imprecisas de los eventos. Así es posible asignar las probabilidades de una manera práctica, sin necesidad de tener una precisión absoluta de esa probabilidad. La ventaja de estos procedimientos es que los cálculos matemáticos no son muy complejos, aunque el costo computacional puede que sí. Entre las técnicas más conocidas para modelar la incertidumbre están las redes Bayesianas y las cadenas de Markov.

En el caso de la ambigüedad y la vaguedad, en donde no es posible definir de manera precisa la verdad o falsedad de una afirmación, el modelado de la incertidumbre se puede hacer bajo la teoría de la lógica borrosa, donde se usan elementos del lenguaje que asocian *grados de pertenencia* de una forma natural a los eventos procesos en cuestión [46]. A esta lógica nos referiremos más en detalle en los siguientes apartados.

### 3.3.2 Fundamentos de la Lógica Borrosa

La lógica borrosa es una lógica multivaluada que extiende la lógica clásica. Esta última asigna a sus enunciados únicamente valores de falso o verdadero (binario), a pesar de que el razonamiento humano utiliza valores de verdad que no necesariamente son binarios.

La lógica borrosa es un superconjunto de la lógica convencional (booleana) que ha sido adaptada para integrar el concepto de *parcialmente cierto*, es decir, valores de certidumbre intermedios entre lo *totalmente cierto* y lo *totalmente falso*. Por ejemplo, al clasificar a la *gente joven*, como primer intento podemos etiquetar como rango superior la edad de 20 años. Como se refleja en la figura 3.17, de esta forma obtenemos un conjunto de gente joven integrado por elementos cuyas edades están comprendidas en un intervalo fijo  $B = [0, 20]$ . Pero, ¿es lógico que alguien en su vigésimo cumpleaños sea considerado joven y al día siguiente no lo sea?.

Una forma más natural de construir este conjunto es modificando la separación entre *joven* y *no joven*. Haremos esto permitiendo no sólo el doble enunciado de la lógica clásica:

Sí él/ella pertenecen al conjunto de gente joven o No él/ella no pertenecen al conjunto de gente joven.

Sino que utilizaremos alternativamente este otro:

Él/ella pertenece un poco más al conjunto de gente joven o No, él/ella casi ni pertenece al conjunto de gente joven.

De esta forma, el conjunto *gente joven* lo hemos sometido a un proceso de *borrosificación*, en donde la pertenencia de un elemento a este conjunto deja de tener los valores cierto (1) o falso (0), y puede adoptar cualquier valor entre estos dos extremos, como queda expresado en la figura 3.18.

En general, la lógica borrosa pretende producir resultados útiles a partir de datos imprecisos. La lógica borrosa se basa en los conjuntos borrosos, en los que a cada

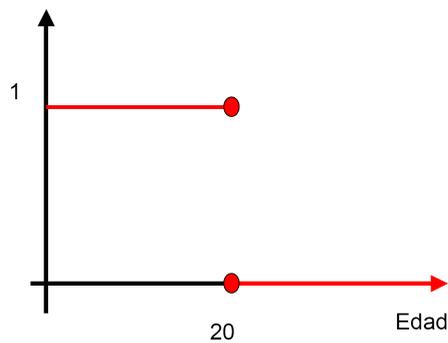


Figura 3.17: Representación del conjunto de gente joven, según la definición de conjunto clásico.

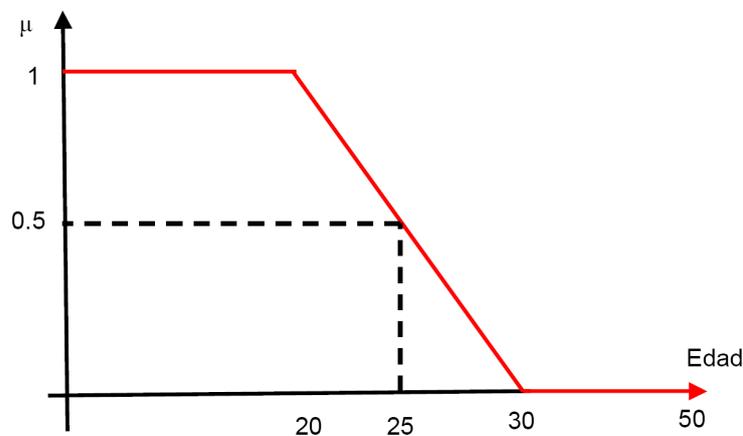


Figura 3.18: Representación del conjunto de gente joven, según la teoría de conjuntos borrosos.

elemento del universo se le asocia un grado de pertenencia al conjunto, definido en el intervalo  $[0,1]$ . En esto difieren de los conjuntos clásicos ya que la función de pertenencia en estos se circunscribe a dos valores: 1 o 0.

### Funciones de Pertenencia

Si  $X$  es el *Universo de discurso* y sus elementos se denotan por  $x$ , un conjunto borroso  $A$  en  $X$  se define por los pares ordenados  $(x, \mu_A(x) \mid x \in X)$ , siendo  $\mu_A(x)$  la función de pertenencia (FP) de cada elemento  $x$  al conjunto  $A$ . De esta forma la FP aplica a cada elemento de  $X$  un valor de pertenencia o grado de pertenencia continuo entre 0 y 1.

Los métodos de determinación de las FP que se utilizan en lógica borrosa son diversos dependiendo de la información que se posea sobre el sistema, las características del propio sistema etc. En ocasiones, la información se toma de histograma de frecuencia u otras curvas probabilísticas, o bien puede utilizarse el aprendizaje o la adaptación, por ejemplo mediante la utilización de redes neuronales, estable-

ciendo el tipo de función y ajustando posteriormente sus parámetros según cierto procedimiento de aprendizaje.

Las diferentes formas de las FP se suelen construir a partir de ciertas funciones básicas y nos permiten representar gráficamente un conjunto borroso. En el eje de abscisas se representa el universo de discurso, mientras que en el eje de ordenadas se sitúan los grados de pertenencia en el intervalo  $[0, 1]$ . Las funciones de pertenencia más simples son las definidas a partir de tramos lineales. De éstas, las más utilizadas son las de forma triangular y trapezoidal, como se representan en la figura 3.19.

Las funciones de pertenencia basadas en la curva de distribución Gaussiana y de tipo campana son también muy utilizadas para especificar conjuntos borrosos, ya que tienen la ventaja de ser continuas no sólo en valor, sino también en sus derivadas. En la figura 3.20 se muestran dos funciones de pertenencia tipo Gauss y otra tipo campana. La función campana queda definida por tres parámetros, uno más que la función Gaussiana, definiciones más ajustadas de las funciones de pertenencia.

Aunque las funciones de pertenencia Gaussiana y campana exhiben continuidad en la derivada, no son capaces de ajustar funciones de pertenencia asimétricas muy importantes en ciertas aplicaciones. La función de pertenencia basada en la curva sigmoideal, mostrada en la figura 3.21 permite sintetizar funciones de pertenencia asimétricas.

Otro tipo de funciones de pertenencia muy utilizadas son las basadas en curvas polinómicas cuadráticas o cúbicas como las mostradas en la figura 3.22. La FP de representada a la izquierda es una curva polinomial asimétrica abierta a la izquierda conocida como función  $Z$ ; la representada a la derecha es la imagen espejo de la anterior y se le conoce como función  $S$ , y la representada en el centro se trata de una curva  $\pi$ .

Un conjunto borroso puede expresarse lingüísticamente con sentencias vagas o borrosas, y viceversa, dado que existe una correspondencia biyectiva entre la teoría de conjuntos borrosos y la lógica borrosa. La posibilidad de hacer corresponder a las expresiones lingüísticas vagas o borrosas unas funciones de pertenencia es la característica más importante de la lógica borrosa y la base de la inferencia borrosa.

### Operadores Borrosos

Dado que en lógica borrosa la verdad de cualquier afirmación es una cuestión de grado, necesitamos conocer cómo relacionar las operaciones lógicas con la inferencia borrosa. Se trata de determinar qué funciones conservan los resultados de la tabla de verdad de la operación lógica (AND, por ejemplo), y además extender la esencia de este conectivo a todos los números reales entre 0 y 1.

Una respuesta para el conectivo AND es la operación *mínimo*. Es decir, el resultado de la operación  $A \text{ AND } B$ , donde  $A$  y  $B$  toman valores en el rango  $[0,1]$ , es un conjunto borroso donde cada valor de pertenencia se obtiene utilizando la función  $\min(A,B)$ :

$$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)) \quad (3.25)$$

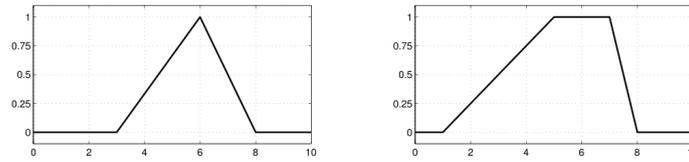


Figura 3.19: Representación de funciones de pertenencia triangular y trapezoidal.

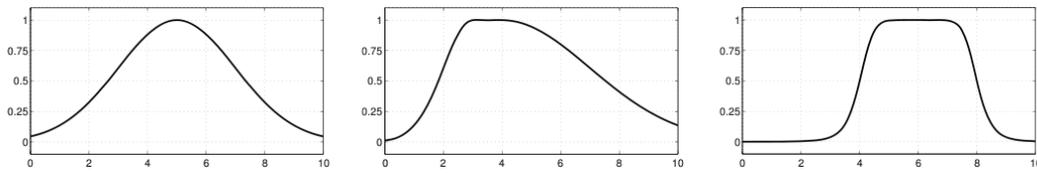


Figura 3.20: Representación de funciones de pertenencia Gaussiana y campana.

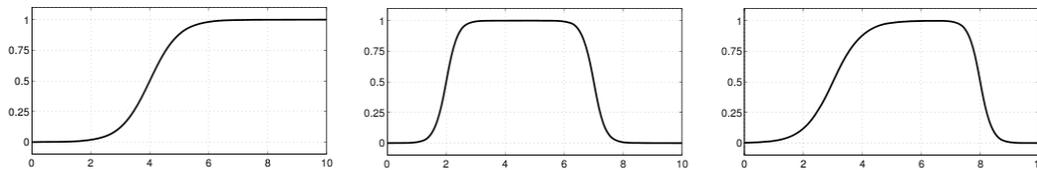


Figura 3.21: Representación de funciones de pertenencia sigmooidal y asimétricas.

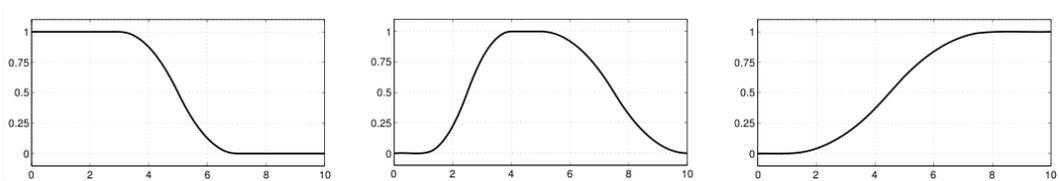


Figura 3.22: Representación de funciones de pertenencia basadas en curvas polinomiales.

Utilizando el mismo criterio, podemos extender la operación lógica OR mediante la función máximo, de forma que  $A \text{ OR } B$  proporciona un conjunto borroso cuyos vectores de pertenencia son:

$$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)) \quad (3.26)$$

Finalmente, la operación  $NOT A$  podemos extenderla en la lógica borrosa mediante la operación  $1-A$ .

$$\mu_{A^c}(x) = 1 - \mu_A(x) \quad (3.27)$$

A los operadores que pueden utilizarse para generalizar el contenido lógico AND al ámbito de la lógica borrosa se les denomina *t-normas*, mientras que los que generalizan el conectivo OR se denominan *t-conormas*.

En la figura 3.23 se muestra cómo estos operadores se corresponden con los conectivos lógicos clásicos cuando las FP se limitan a tomar los valores extremos 0 y 1.

En la figura 3.24 se ilustra cómo opera estos conectivos borrosos de conjunción (AND-mínimo) y disyunción (OR-máximo), y la operación de negación, cuando se aplican sobre valores lógicos clásicos (0 y 1), y sobre valores borrosos pertenecientes al intervalo [0,1]. La parte superior de la figura representa la situación clásica, mientras que en la parte inferior los operadores se aplican a funciones de pertenencia borrosa.

### 3.3.3 Inferencia borrosa. Reglas de implicación.

Los conjuntos y operadores borrosos son las sentencias y conectivos lingüísticos de la lógica borrosa. Pero para poder expresar algo útil se necesita hacer frases completas. Las afirmaciones condicionales, o reglas de implicación son las que lo hacen posible.

Como en cualquier otra lógica, el método para obtener conclusiones a partir de la composición de conjuntos borrosos de entrada con reglas de implicación de la forma *Si...entonces... (If...then...)*, es de especial interés en lógica borrosa. Al mecanismo subyacente en esta composición entre una regla de implicación y una entrada borrosa es a lo que se denomina *Inferencia borrosa*.

Una regla de implicación sencilla en lógica borrosa asume la forma:

$$\text{Si } x \text{ es } A \text{ entonces } y \text{ es } B \quad (A \rightarrow B) \quad (3.28)$$

en donde  $A$  y  $B$  son sentencias borrosas y están modeladas por conjuntos borrosos. La expresión describe una relación entre dos variables  $X$  y  $Y$ . La parte  $x \text{ es } A$  es el *antecedente* o premisa, mientras que la parte  $y \text{ es } B$  se le conoce como *consecuente* o conclusión.

Un ejemplo de regla borrosa sería:

Si la temperatura es alta entonces la demanda de energía es alta

A	B	A and B	$min(A, B)$
0	0	0	0
0	1	0	0
1	0	0	0
1	1	1	1

AND

A	B	A or B	$max(A, B)$
0	0	0	0
0	1	1	1
1	0	1	1
1	1	1	1

OR

A	not A	$1 - A$
0	1	1
1	0	0

NOT

Figura 3.23: Correspondencia entre los conectivos borrosos y los operadores binarios clásicos

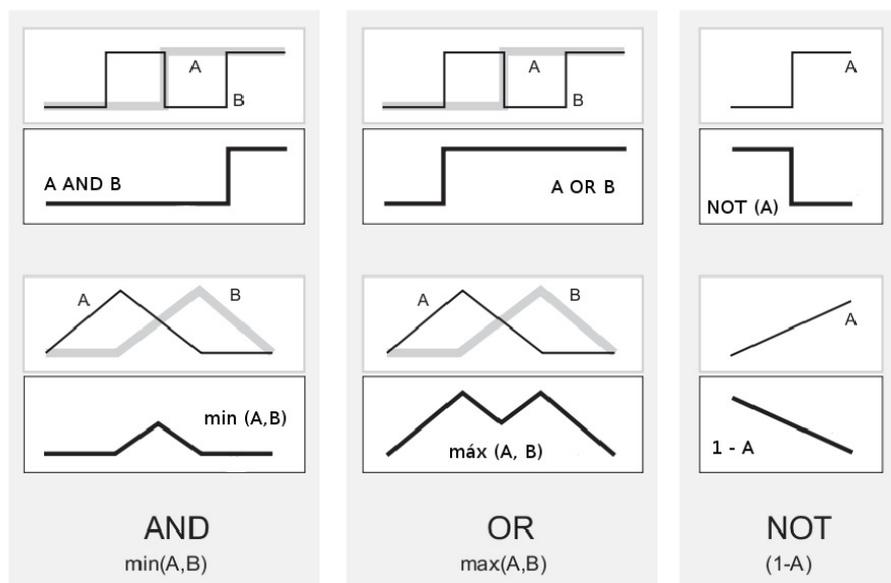


Figura 3.24: Representación gráfica de la relación entre operadores lógicos básicos en lógica clásica y lógica borrosa.

expresión donde hay implícitamente definidos dos conjuntos borrosos *temperatura alta* y *demanda de energía alta*, cada uno de ellos caracterizados por funciones de pertenencia definidas sobre los elementos de los universos correspondientes.

La relación borrosa implícita en la implicación borrosa. Se concreta a través de una operación entre los conjuntos borrosos antecedente y consecuente. Así, la función de pertenencia asociada a esta relación puede obtenerse como el mínimo (o el producto) de las funciones de pertenencia  $\mu_A(x)$  y  $\mu_B(x)$ :

$$\mu_{A \rightarrow B}(x, y) = \min(\mu_A(x), \mu_B(y))$$

Evaluar una inferencia borrosa una vez que se conoce una entrada comporta dos pasos: primero evaluar el antecedente, lo que supone *borrosificar* la entrada y aplicar un operador borroso para componerla con el antecedente de la regla, y segundo trasladar este resultado al consecuente para obtener la salida. El procedimiento de composición, según una de las interpretaciones de entre las muchas posibles, se ilustra en la figura 3.25. Tal como se puede apreciar en la figura, la máxima coincidencia entre los valores de pertenencia del antecedente y la entrada sirve

como valor de truncamiento del conjunto borroso del consecuente, y esa función de pertenencia truncada será el resultado de la inferencia borrosa.

El antecedente de una regla puede tener varias partes, es decir, ser una sentencia compuesta de varias sentencias simples enlazadas mediante operadores AND. Por ejemplo:

Si el cielo está gris y el viento es fuerte y el barómetro está cayendo, entonces ...

En este caso todas las partes del antecedente se calculan simultáneamente y se reducen a un número utilizando operadores borrosos. El procedimiento de composición de los antecedentes con las distintas entradas se ilustra gráficamente en la figura 3.26.

También el consecuente de una regla puede tener varias partes, como en la siguiente implicación:

Si la temperatura está fría entonces la válvula de agua caliente debe abrirse y la de agua fría debe cerrarse

En este caso todos los consecuentes se verán afectados de igual manera por el resultado del antecedente, de la forma descrita en las reglas simples. La figura 3.27 muestra un ejemplo del resultado de aplicación de una inferencia borrosa a un sistema con múltiples reglas y múltiples antecedentes.

#### 3.3.4 Sistemas de Inferencia Borrosa

Un sistema de inferencia borrosa (*FIS*) (*Fuzzy Inference System*) utiliza la inferencia como la máquina de cálculo para procedimientos cuyas entradas y salidas pueden ser números precisos (no borrosos); este es el caso, por ejemplo de los sistemas de control borroso. Los FIS han sido aplicados con éxito en campos tales como control automático, clasificación de datos, análisis de decisiones, sistemas expertos y visión artificial. Debido a su naturaleza multidisciplinar, los FIS son conocidos por una variedad de nombres, tales como sistemas basados en reglas borrosas, sistemas borrosos expertos, modelos borrosos, memorias asociativas borrosas, controladores borrosos o simplemente sistemas borrosos.

Básicamente este tipo de sistemas de inferencia borrosa se componen de cinco bloques, tal como se muestra en la figura 3.28: una base de reglas, que contiene un cierto número de reglas de implicación borrosa; una base de datos que define las funciones de pertenencia de los conjuntos borrosos usados en las reglas borrosas; una unidad de toma de decisiones donde se realizan las operaciones de inferencia según las reglas; una interfaz de borrosificación en la que se transforman las entradas precisas en grados de equivalencia con valores lingüísticos; y una interfaz de desborrosificación que transforma los resultados borrosos de la inferencia en una salida precisa.

Existen tres tipos de modelos borrosos que se diferencian básicamente por el consecuente de las reglas. El primero lo constituyen los sistemas tipo Mamdani. ,

premisa 1 (hecho):  $x$  es  $A'$   
 premisa 2 (regla): si  $x$  es  $A$  entonces  $y$  es  $B$

---

consecuencia (conclusión)  $y$  es  $B'$

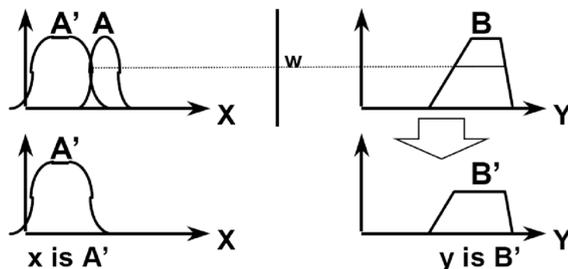


Figura 3.25: Una inferencia borrosa con una implicación de un antecedente único.

premisa 1 (hecho):  $x$  es  $A'$  e  $y$  es  $B'$   
 premisa 2 (regla): si  $x$  es  $A$  e  $y$  es  $B$  entonces  $z$  es  $C$

---

consecuencia (conclusión)  $z$  es  $C'$

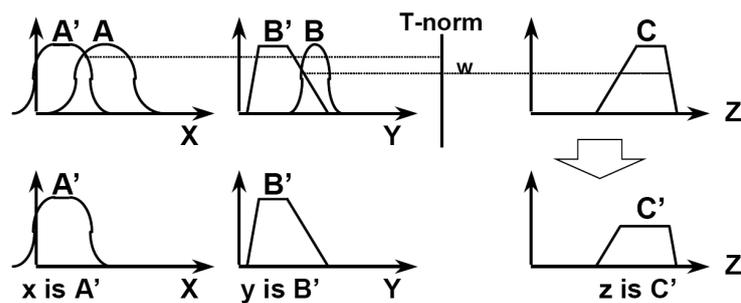


Figura 3.26: Una regla de implicación con múltiples antecedentes.

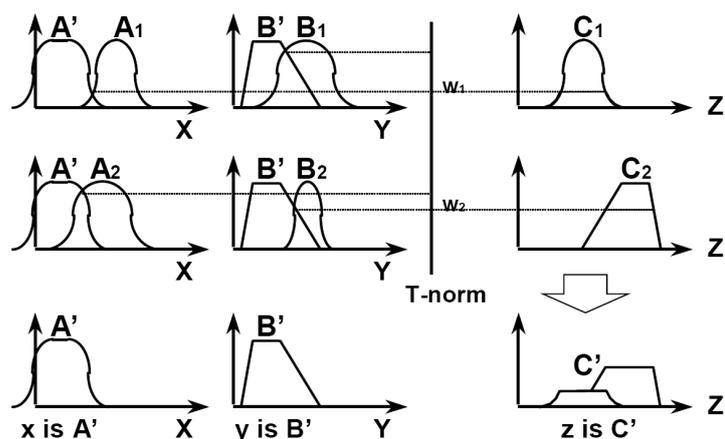


Figura 3.27: Múltiples reglas con múltiples antecedentes.

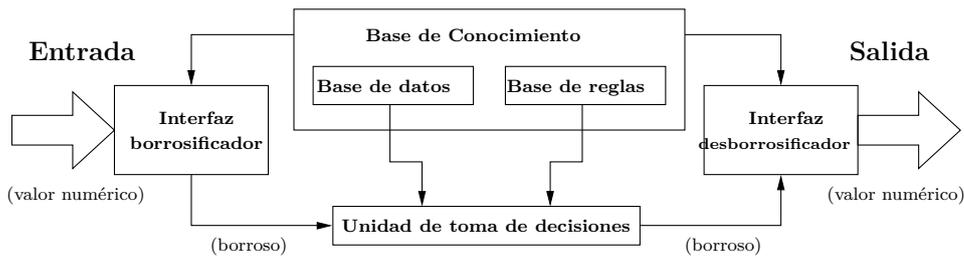


Figura 3.28: Sistema de inferencia borroso (FIS).

que se aplicó al primer sistema de control construido utilizando la teoría de conjuntos borrosos, y fue propuesto por Ebrahim Mamdani [63] en un intento de controlar una máquina de vapor y una caldera combinada sintetizando un conjunto de reglas de control lingüísticas obtenidas de la experiencia de los obreros. Los consecuentes de las reglas son funciones de pertenencia, y después de que estas reglas son evaluadas mediante un operador de agregación, que generalmente es la función máximo, se obtiene un conjunto borroso que luego es desborrosificado.

El segundo es el denominado modelo de Sugeno, también conocido por modelo borroso TSK ya que fue propuesto por Takani, Sugeno y Kang [94] en un esfuerzo de desarrollar una aproximación sistemática a la generación de reglas borrosas a partir de un conjunto de datos entrada-salida. En este tipo de sistemas los consecuentes de las reglas son funciones monótonas no-decrecientes; la salida inferida de cada regla se define como un valor preciso, y la salida global como el promedio ponderado de la salida de cada regla. Un modelo TSK tiene la siguiente forma:

$$\text{Si } x \text{ es } A \text{ e } y \text{ es } B \text{ entonces } z = f(x, y)$$

donde el consecuente es una combinación lineal de las variables de entrada.

El tercer tipo de sistemas de inferencia borrosos lo constituyen los modelos borrosos de Tsukamoto. En estos modelos el consecuente de cada regla se representa por un conjunto borroso con una función de pertenencia monótona. La salida inferida por cada regla es un valor preciso y asociado a por la fuerza de activación de la regla, y la salida global se toma como la media ponderada de todas. Estos modelos no son muy utilizados por no ser tan intuitivos como los de Mamdani o Sugeno.

### 3.3.5 Sistemas de inferencia ANFIS

Los sistemas de inferencia borrosa y las estructuras neuronales pueden combinarse para obtener estructuras más eficientes e interpretables en sus modos de operación. Es este campo relativamente nuevo pero de gran producción científica, por lo que en la última década se han descrito y propuesto varias y diferentes maneras de iteración entre estos dos campos.

Los sistemas de inferencia borrosa (FIS) y las redes neuronales artificiales (ANN) son herramientas adecuadas para modelar el comportamiento experto. Si el conocimiento se posee en forma de reglas lingüísticas, podemos construir un sistema borroso, y si poseemos datos o podemos aprender de simulaciones de procesos reales

entonces podemos utilizar redes neuronales. La razón más importante para combinar los FIS con las ANN es el aprovechamiento de la capacidad de aprendizaje de éstas últimas. Aprendizaje, en este caso, significa aprender reglas lingüísticas y/o funciones de pertenencia, u optimizar las existentes a partir de datos presentados como un problema de aprendizaje supervisado o no supervisado.

La estructura básica de un sistema clásico de inferencia borrosa es un modelo que proyecta las características de entrada a funciones de pertenencia, entradas de funciones de dependencia a reglas, reglas a un conjunto de características de salida, características de salida a funciones de pertenencia de salida, y la función de salida de pertenencia a un simple valor de salida o decisión asociada con la salida. Todos estos procesos se desarrollan utilizando sólo funciones de pertenencia fijas que se eligen arbitrariamente. Este sistema de inferencia borrosa se aplica sólo a sistemas modelo en los que la estructura de reglas son esencialmente predeterminadas por el usuario que interpreta las características de las variables en el modelo.

En algunas situaciones, es muy difícil discernir qué funciones de pertenencia serán adecuadas de la simple observación de los datos. Más que elegir los parámetros asociados con una función de pertenencia arbitraria dada, estos parámetros podrían elegirse adaptando las funciones de pertenencia a los datos entrada/salida para tener en cuenta estos tipos de variaciones en los valores de los datos. En tales casos, las técnicas de aprendizaje neuro-adaptativas pueden ayudar. La forma de las funciones de pertenencia dependen de los parámetros, y cambiando estos parámetros cambia la forma de la función de dependencia. En lugar de mirar los datos para elegir los parámetros de la función de pertenencia, estos se eligen automáticamente.

Existen diversas formas de integrar ANN y FIS. Una posible clasificación de estos sistemas híbridos podría ser:

- **Redes Neuronales Borrosas:** Los métodos borrosos son utilizados para mejorar las características de las ANN empleando reglas borrosas para cambiar los parámetros de aprendizaje [13], o creando redes que puedan trabajar con entradas borrosas [76].
- **Sistemas Concurrentes Neuro-borrosos:** Una ANN y un FIS trabajan al mismo tiempo sobre el mismo problema, pero sin influenciarse mutuamente. Generalmente la ANN preprocesa entradas o postprocesa salidas del FIS
- **Sistemas Neuro-borrosos Cooperativos:** Se utiliza una ANN para determinar las reglas, pesos y/o funciones de pertenencia de un FIS [34].
- **Sistemas Híbridos Neuro-Borrosos:** Una ANN y un FIS se combinan para formar una arquitectura homogénea. El sistema puede interpretarse tanto como una ANN con parámetros borrosos como un FIS implementado en forma paralela distribuida. En estos sistemas los conjuntos borrosos pueden interpretarse como pesos y las variables de entrada y salida, además de las reglas, como neuronas.

Siguiendo la metodología implícita en los sistemas híbridos neuro-borrosos, en 1993 J.R. Jang [42] desarrolló un nuevo modelo al que denominó ANFIS por *Adaptive Network-based Fuzzy Inference System*.

Un sistema ANFIS es un modelo híbrido neuro-borroso donde las reglas se aplican siguiendo una estructura de red tipo red neuronal, que puede ser interpretada como una red neuronal con parámetros borrosos o como un sistema borroso con parámetros o funcionamiento distribuidos.

Un sistema ANFIS integra las mejores características de los sistemas borrosos y de las redes neuronales. De los sistemas borrosos se utiliza la representación del conocimiento previo en un conjunto de restricciones (topología de la red) para reducir el espacio de búsqueda de optimización, y de las redes neuronales la adaptación de propagación inversa a la red estructurada para automatizar la sintonización de los parámetros. La parte premisa de una regla define un subespacio borroso, mientras que la parte consecuente especifica la salida dentro de este subespacio.

La estructura ANFIS permite el uso de métodos cualitativos y cuantitativos en la construcción de modelos. Este modelo permite integrar la información incluida dentro de un conjunto de datos con el conocimiento de expertos expresados en forma lingüística y a través de la teoría de conjuntos borrosos. De esta manera un modelo ANFIS involucra todo el conocimiento disponible [60].

### Arquitectura ANFIS

La arquitectura ANFIS investigada con más frecuencia la del modelo Sugeno de primer orden, debido a su eficiencia y transparencia. Este sistema híbrido neuro-fuzzy es funcionalmente equivalente al mecanismo de inferencia Takagi-Sugeno. Para este sistema de inferencia de primer orden hay un conjunto de reglas borrosas en las que los niveles de activación se calculan utilizando el operador AND que puede modelarse por una t-norma continua (producto). Las salidas individuales de cada regla se obtienen como una combinación lineal entre los parámetros del antecedente de cada regla. La salida de control del modelo se obtiene por la normalización de los grados de activación de las reglas multiplicado por la salida individual de cada regla.

Una arquitectura representativa ANFIS con dos entradas ( $x$  and  $y$ ), una salida ( $f$ ) y una base de reglas con cuatro reglas borrosas

$$\begin{aligned}
 \text{Regla 1: Si } x \text{ es } A_1 \text{ y } y \text{ es } B_1 \text{ entonces } f_1 &= p_1x + q_1y + r_1 \\
 \text{Regla 2: Si } x \text{ es } A_1 \text{ y } y \text{ es } B_2 \text{ entonces } f_2 &= p_2x + q_2y + r_2 \\
 \text{Regla 3: Si } x \text{ es } A_2 \text{ y } y \text{ es } B_1 \text{ entonces } f_3 &= p_3x + q_3y + r_3 \\
 \text{Regla 4: Si } x \text{ es } A_2 \text{ y } y \text{ es } B_2 \text{ entonces } f_4 &= p_4x + q_4y + r_4
 \end{aligned} \tag{3.29}$$

se ilustra en la figura 3.29. Ésta consta de cinco capas: borrosificación adaptativa, reglas borrosas, normalización, implicación adaptativa y salida. Cada capa representa una operación del mecanismo de inferencia borrosa.

Todos los nodos de una misma capa tienen la misma función. Los nodos que están representados como cuadrados en la figura son los adaptables, y sus parámetros son ajustables.

El dominio de  $x$  se ha dividido en las regiones  $A_1$  y  $A_2$ , y el dominio de  $y$  en las regiones  $B_1$  y  $B_2$ . De esta forma, el dominio del problema, esto es, el plano  $X \times Y$ ,

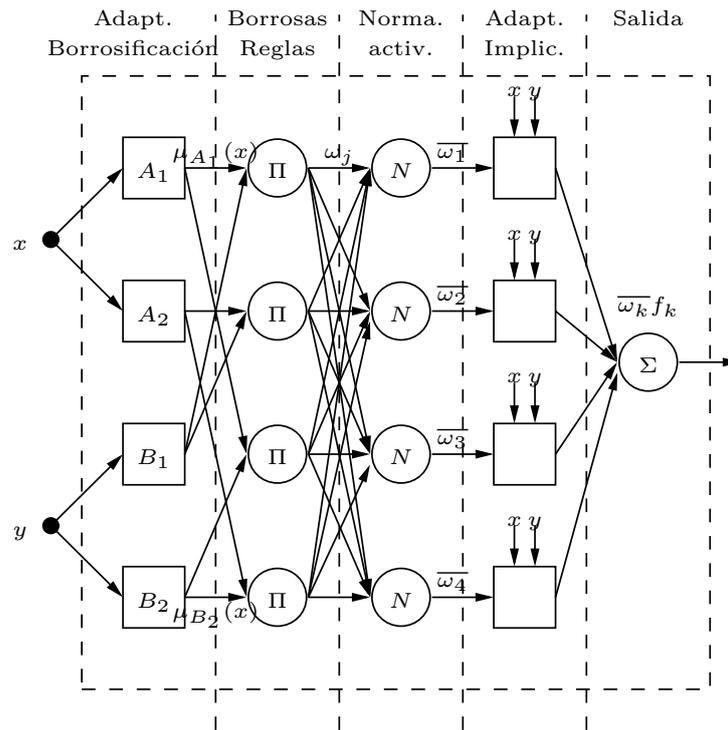


Figura 3.29: Arquitectura ANFIS, con dos entradas, una salida y cuatro reglas.

queda dividido en las regiones 1, 2, 3 y 4, como se ilustra en la figura 3.30, que resultan de la intersección de  $A_1, A_2, B_1$  y  $B_2$ .

A cada una de las cuatro regiones en que se divide el dominio se le asigna un modelo lineal de la forma  $z = px + qy + r$ , que representa la relación de dependencia entre  $z$  y  $(x, y)$ . El modelo final queda representado como un conjunto de reglas, donde el antecedente permite determinar a qué región pertenece el punto que se desea evaluar  $(x, y)$ , mientras que el consecuente corresponde al modelo lineal.

El proceso de inferencia realizado para calcular el valor de salida dada una entrada  $(x, y)$  es el siguiente:

En la primera capa las entradas se corresponden con las entradas al sistema  $(x, y)$  y la salida es el grado de pertenencia para el cual la variable de entrada satisface el término lingüístico  $A_i$  asociado al nodo. Ésta es una de las dos capas que tienen parámetros ajustables, como se ha dicho anteriormente; en este caso los parámetros son los que representan las particiones difusas usadas en las reglas, es decir, se corresponden con los parámetros de las funciones de pertenencia de las entradas:

$$O_i^1 = \mu_{A_i}(x) \tag{3.30}$$

En la segunda capa cada nodo calcula el grado de activación de la regla asociada al mismo. Estos nodos están representados por  $\Pi$  en la figura 3.29 porque pueden representar cualquier T-norma para modelar la operación lógica AND. Se suelen

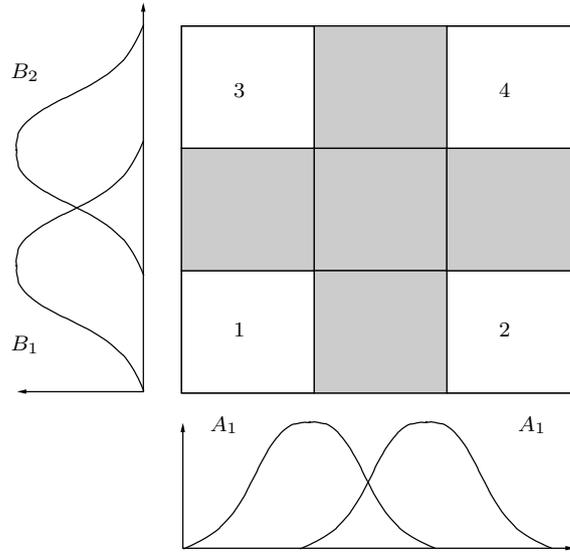


Figura 3.30: Arquitectura ANFIS: dominio del problema.

denominar como nodos de reglas. El grado de activación de la regla se obtiene multiplicando las entradas (salida de los nodos de la primera capa), es decir:

$$O_i^2 = \omega_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i = 1, 2 \dots \quad (3.31)$$

En la tercera capa cada nodo representado por  $N$  en la figura 3.29 indica la normalización de los grados de activación. Su salida es el grado de activación normalizado (respecto a la suma de los grados de activación) de la regla  $i$ . Por tanto, en esta capa se establece el porcentaje en el que cada regla aporta a la solución final:

$$O_i^3 = \bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2} \quad i = 1, 2 \dots \quad (3.32)$$

En la cuarta capa la salida de cada nodo se corresponde con el producto entre el grado de activación normalizado (salida de la tercera capa) y la salida individual de cada regla calculada por los nodos de esta capa.

$$O_i^4 = \bar{\omega}_i f_i = \bar{\omega}_i (p_i x + q_i y + r_i) \quad i = 1, 2 \dots \quad (3.33)$$

donde  $p_i, q_i$  y  $r_i$  forman el conjunto de parámetros que se conocen como *parámetros del consecuente*. Esos parámetros, como resulta obvio, son los coeficientes de las funciones lineales que forman el consecuente de las reglas, y son ajustables, como los de la primera capa.

La quinta y última capa tiene un único nodo que calcula la salida total del sistema (agregación) como la suma de todas sus señales de entradas individuales:

$$O^5 = z_0 = \sum_i \bar{\omega}_i f_i = \frac{\sum_i \omega_i f_i}{\sum_i \omega_i} \quad (3.34)$$

En resumen, cada una de las capas tiene una misión concreta dentro del sistema: la primera capa representa la capa de pertenencia, la segunda capa se usa para generar el grado de disparo de la regla (II -norma), la tercera capa actúa de normalizador, la cuarta capa calcula la salida y la última capa combina todas las salidas en una en su único nodo.

#### Algoritmo de Aprendizaje

En la arquitectura ANFIS hay que entrenar dos conjuntos de parámetros: el primero,  $S1$ , representa las particiones borrosas usadas en las reglas y por lo tanto los parámetros son los de las funciones de pertenencia de las entradas y un conjunto  $S2$  de los coeficientes de las funciones lineales en los consecuentes.

Los algoritmos de aprendizaje que suelen emplearse son de gradiente descendente para optimizar los parámetros del antecedente y el algoritmo de mínimos cuadrados para determinar los parámetros lineales del consecuente. Debido a esta combinación la regla de aprendizaje se conoce como *regla de aprendizaje híbrido*. De una forma general, el proceso de aprendizaje del ANFIS intenta desplazar los valores de los parámetros de las funciones de pertenencia de forma proporcional a la derivada del error respecto a ese parámetro (gradiente descendente). Esto lo hace calculando la suma de los errores cuadráticos medios (diferencia entre la salida deseada y la salida de la red), y utiliza el gradiente de ese error en negativo para minimizar el error. Para conseguirlo, multiplica cada parámetro del antecedente por un valor proporcional al gradiente respecto de ese parámetro de entrada (en negativo). Ese valor proporcional es lo que se conoce como factor de aprendizaje. Con eso se van ajustando los parámetros del antecedente de forma que se va reduciendo el error producido por el sistema ANFIS. El problema principal se da cuando el gradiente del error es muy pequeño, pues entonces hacen falta muchas iteraciones para disminuir el error.

Para poder aplicar este aprendizaje en grupo, en cada etapa de entrenamiento se debe ejecutar un paso hacia delante (*forward*) y otro hacia atrás (*backward*):

1. El paso hacia delante: los parámetros de las funciones de pertenencia (capa 1) se inicializan (sólo en el primer paso de entrenamiento) y se presenta un vector de entrada-salida, se calculan las salidas del nodo para cada capa de la red y se obtienen los parámetros del consecuente (capa 4) usando el método de mínimos cuadrados. Con los parámetros del consecuente identificados se calcula el error como la diferencia entre la salida obtenida en la red y la salida deseada (que se presentó en los pares de entrenamiento). Para medir el error de entrenamiento suele emplearse la suma de errores cuadráticos. En este paso por tanto, los parámetros  $S1$  no se modifican y se recalculan sólo los  $S2$ .
2. El paso hacia atrás: se propagan las señales de error desde la salida, en dirección hacia las entradas. Para cada dato de entrenamiento se acumula el vector gradiente. Al final de este paso para todos los datos de entrenamiento, los parámetros en la capa 1 (parámetros de las funciones de pertenencia) se actualizan por el método gradiente descendente en el que, como se ha explicado anteriormente, se multiplica cada parámetro por una magnitud proporcional a la derivada del error respecto a ese parámetro (gradiente descendente). En

este paso por tanto, los parámetros  $S2$  no se modifican y sólo se reajustan los  $S1$ .

### 3.4 Sumario

El reconocimiento de patrones tradicionalmente se ha abordado desde un punto de vista estadístico, hablándose de reconocimiento estadístico de patrones (REP). Sin embargo, hay que decir que existen otros enfoques de naturaleza no estadística. Así, por ejemplo, están las soluciones planteadas desde la perspectiva del *soft computing*, rama de la inteligencia artificial centrada en el diseño de sistemas inteligentes capaces de manejar adecuadamente información imprecisa, incierta y/o incompleta, y en donde las redes de neuronas artificiales (ANN), y los sistemas de inferencia adaptativos neuro-borrosos (ANFIS) tienen un son claros exponentes de estas técnicas.

En las dos últimas décadas, los avances en el campo de la neurocomputación han sido espectaculares, en particular el desarrollo de redes neuronales artificiales (ANN). El auge de estos sistemas se debe más al éxito obtenido en aplicaciones reales, como por ejemplo: reconocimiento de patrones, predicción, optimización o control, que a la semejanza con el modelo biológico. La adaptabilidad de las ANN es crucial para los problemas de reconocimiento no solamente para mejorar la tasa de generalización sino también para permitir un buen comportamiento frente a cambios en el entorno o frente a datos de entrada incompletos o ruidosos. En este sentido los métodos basados en ANN obtienen mejores resultados que los métodos clásicos.

Los sistemas basados en lógica borrosa pueden combinarse con las estructuras de tipo neuronal y con su probada capacidad de aprendizaje, para dar lugar a los denominados sistemas neuro-borrosos. Estos sistemas son capaces de incorporar información apriorística basada en el conocimiento experto y, además optimizar sus estructuras y parámetros para adaptarse a las condiciones del problema. La inferencia borrosa es, por lo tanto, una alternativa interesante en sistemas en donde la incertidumbre asociada con las variables del sistema a modelar no radica solamente en los datos cuantitativos que se tienen sino también en incertidumbres del tipo de vaguedad o ambigüedad o en datos cualitativos que provienen de la opinión o concepto de expertos. Es decir, el razonamiento difuso permite involucrar en el modelado de un sistema el conocimiento experto y la experiencia de las personas, además de datos numéricos. El razonamiento difuso además permite utilizar los conceptos de las redes neuronales para hacer más efectivo el sistema de razonamiento. Las aplicaciones de la inferencia y el razonamiento difuso son cada vez más amplias en las áreas de la ingeniería, en donde la incertidumbre es parte fundamental para modelar sistemas.

En este capítulo hemos hecho una introducción a la utilización de redes neuronales artificiales (ANN) y sistemas de inferencia adaptativos neuro-borrosos (ANFIS), como técnicas de clasificación de patrones. Sin llegar a ser una revisión exhaustiva del campo del reconocimiento de patrones, ni siquiera de una parte de él, se ha realizado una descripción abreviada del uso de estas técnicas concretas con la pretensión de proporcionar la base teórica necesaria para hacer más comprensible una de las partes más destacadas de nuestro trabajo.



# Capítulo Cuatro

---

## Metodología de Análisis de las Imágenes Radiográficas

---

Nuestra propuesta para el diseño de un sistema de inspección automática de imágenes radiográficas de uniones soldadas sigue el esquema general clásico mostrado en la figura 4.1, con las etapas de preprocesado de la imagen, segmentación del cordón de soldadura, selección de los candidatos a defectos, extracción de características relevantes de los candidatos a defectos y finalmente clasificación de los mismos. En dicha propuesta hemos desarrollado y adaptado soluciones innovadoras para las etapas más críticas, que son las de segmentación del cordón de soldadura, detección de candidatos a defectos e identificación de los mismos. En la exposición y justificación de las técnicas y algoritmos desarrollados para este fin se centrará este capítulo.

La implementación de estas técnicas se realizó con el lenguaje técnico de computación Matlab (MathWorks, Inc). Matlab integra herramientas de procesamiento, visualización y programación, en un entorno fácil de utilizar y con una notación matemática muy familiar. Una de las aplicaciones específicas que incorpora Matlab, dentro de las llamadas *toolboxes*, es la de procesamiento de imágenes. Esta *toolbox* incorpora una colección de funciones que amplía la capacidad del entorno computacional de la aplicación, y soporta un vasto rango de operaciones de procesamiento de imágenes, incluyendo transformaciones espaciales, operaciones morfológicas, filtrado lineal y diseño de filtros, análisis y realzado de imágenes, operaciones con regiones de interés, etc.

### 4.1 Adquisición de las Imágenes

Las películas radiográficas, como ya se ha indicado, pueden digitalizarse de diversas maneras. La forma más común de digitalización es mediante escáner. En este trabajo se utilizó un escáner UMAX, modelo Mirage II (densidad máxima óptica 3.3; máxima resolución para radiografías 2000 dpi - puntos por pulgada), para escanear las radiografías de la colección del Instituto Internacional de Soldadura<sup>1</sup>(IIW). En la web de la empresa fabricante del escáner [1] se puede encontrar una descripción detallada del digitalizador.

La resolución espacial utilizada en el estudio fue de 500 dpi, totalizando un tamaño promedio de las imágenes de 2900 píxeles (longitud horizontal)  $\times$  950 píxeles (longitud vertical), lo que da como resultado un tamaño promedio por píxel de 50

---

<sup>1</sup>Debidamente autorizado por IIW

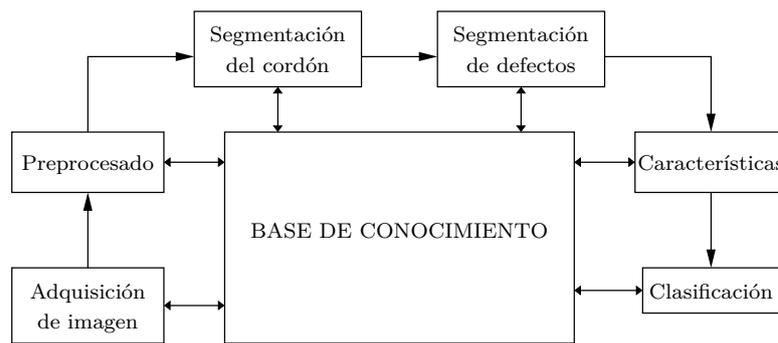


Figura 4.1: Sistema de inspección automática de imágenes radiográficas.

$\mu\text{m}$ . Dicha resolución se adoptó por la posibilidad de detectar y medir defectos de décimas de milímetro, lo que en términos prácticos de inspección radiográfica proporciona una resolución muy superior a la habitual. La resolución adoptada para la escala de niveles de gris fue de 8 bits (256 niveles), ya que el modelo de escáner no permite una mejor resolución. Esto no es un problema dado que el ojo humano no es capaz de reconocer diferencias en la escala de grises por encima de 128 niveles, y las imágenes de 10, 12 ó 16 bits consumen una cantidad adicional considerable de espacio de memoria.

Para el desarrollo del trabajo, como ya se ha indicado, se utilizó la colección de radiografías standard del IIW. Esta colección de imágenes contiene las clases de defectos más frecuentes que pueden aparecer en uniones soldadas, tales como falta de penetración, porosidades, inclusiones lineales y no lineales de escorias, mordeduras, grietas, etc. Entre ellas fueron seleccionadas 86 películas correspondientes a uniones soldadas que contenían las clases de defectos que serán evaluados por el sistema: inclusiones de escoria, porosidad, grietas longitudinales y grietas transversales.

En la figura 4.2 se muestra un ejemplo de imagen radiográfica digitalizada y su histograma en niveles de gris, que nos proporciona información sobre el número de píxeles que hay en cada nivel de intensidad. Esta imagen nos va a servir a lo largo de este capítulo como referencia para mostrar los resultados de las técnicas y algoritmos que se aplican en el sistema.

## 4.2 Preprocesamiento de las Imágenes

Después de digitalizar las películas, es práctica común en los sistemas automáticos de inspección incluir una etapa de preprocesamiento con el propósito específico de reducir/eliminar ruido y mejorar el contraste. Las películas radiográficas generalmente tienen ruido y un contraste deficiente debido a factores intrínsecos relacionados con la técnica de inspección, entre los que se encuentran la iluminación no uniforme y el rango limitado de intensidades del dispositivo de captura de imágenes.

El ruido en las imágenes radiográficas escaneadas se caracteriza generalmente por una proliferación aleatoria de píxeles, con valores de intensidad que difieren de sus píxeles vecinos. En este trabajo se llevaron a cabo dos etapas de preprocesamiento:

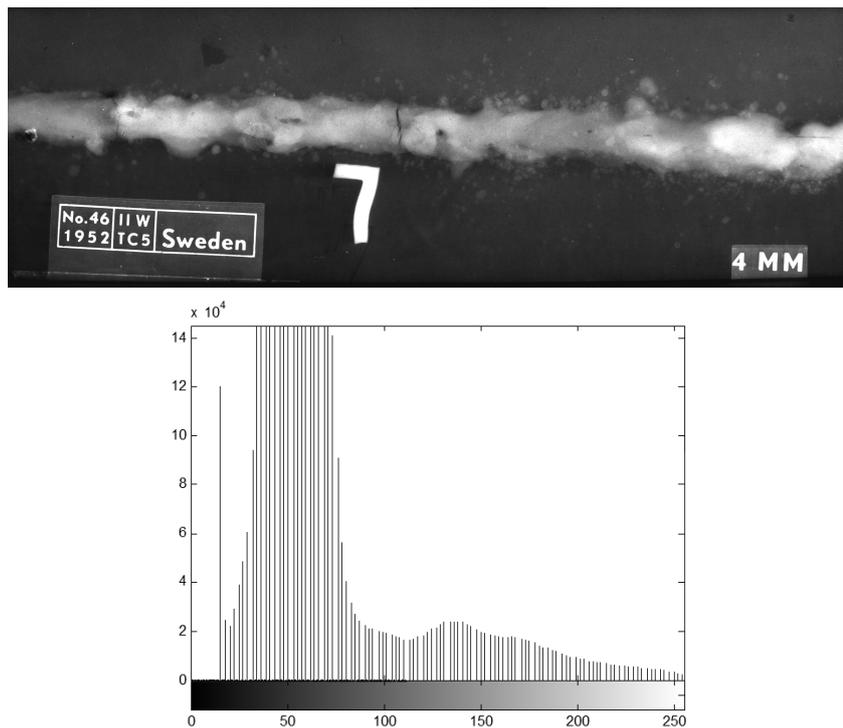


Figura 4.2: Imagen radiográfica digitalizada y abajo su histograma.

en la primera etapa, y con el objetivo de reducir/eliminar ruido, fueron aplicados un filtro adaptativo Wiener [58] y un filtro pasa baja Gaussiano [33]; en la segunda etapa se implementó un algoritmo de ajuste de los valores de intensidad de la imagen. En las dos secciones siguientes se describen estas técnicas de forma detallada.

#### 4.2.1 Reducción-Eliminación de Ruido. Filtrado

Los filtros Wiener son filtros lineales adaptativos basados en las características de varianzas locales de la imagen. Estos filtros suavizan de forma gradual, actuando sobre las áreas de una imagen donde el ruido es muy aparente, pero manteniendo aquellas donde los detalles están presentes y el ruido es menos aparente.

El algoritmo implementado en esta primera etapa de preprocesado utiliza el método del *pixel-wise adaptive Wiener*, basado en el algoritmo desarrollado por Lee en 1980 [58], y que realiza una estimación estadística del vecindario local de cada píxel. Mediante este método se filtra la imagen usando una vecindad de tamaño  $7 \times 7$  para estimar la media ( $\mu$ ) y desviación estándar ( $\sigma^2$ ) de la imagen, a través de la media y varianzas local alrededor de cada píxel.

$$\begin{aligned}\mu &= \frac{1}{N \cdot M} \sum_{n_1, n_2 \in \eta} a(n_1, n_2) \\ \sigma^2 &= \frac{1}{N \cdot M} \sum_{n_1, n_2 \in \eta} a^2(n_1, n_2) - \mu^2\end{aligned}\tag{4.1}$$

donde  $\eta$  es la vecindad local  $N \times M$  de cada píxel de la imagen,  $a(n_1, n_2)$  representa el nivel de gris del píxel situado en las coordenadas  $(n_1, n_2)$ , dentro de la ventana de tamaño  $N \times M$ .

El algoritmo entonces crea un filtro Wiener utilizando la siguiente estimación:

$$b(n_1, n_2) = \mu + \frac{\sigma^2 - v^2}{\sigma^2} (a^2(n_1, n_2) - \mu) \quad (4.2)$$

donde  $\sigma^2$  es la varianza del ruido. Si esta varianza no es conocida, el algoritmo utiliza el promedio de todas las varianzas locales estimadas.

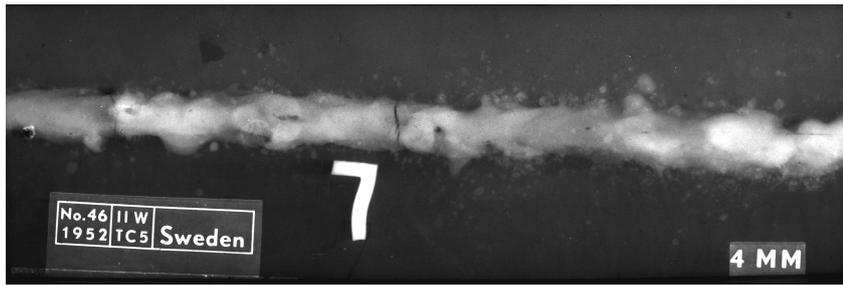
El filtro Wiener se adapta a la varianza local de la imagen de forma que, donde ésta es mayor, el filtro Wiener realiza un suavizado menor, y donde la varianza es menor, el suavizado será mayor. Esta propuesta a menudo produce mejores resultados que el filtrado lineal, ya que el filtrado adaptativo es más selectivo, preservando bordes y otras partes de alta frecuencia de una imagen.

Para ilustrar los resultados obtenidos con esta técnica mostramos en la parte superior de la figura 4.3 la imagen digitalizada de la radiografía original junto a su histograma, y en la misma figura abajo la imagen procesada con el filtro Wiener y el histograma resultante. Las limitaciones de reprografía ineludiblemente asociadas al proceso de impresión de esta memoria ocultan parcialmente el efecto que esta técnica de reducción de ruido produce sobre la imagen radiográfica, siendo mucho más evidente en la comparación de ambos histogramas.

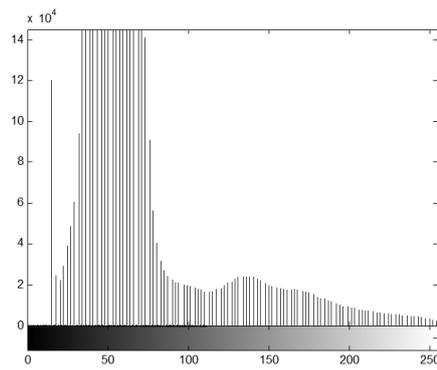
Por otra parte, sabemos que una imagen digital puede contemplarse como una representación de la distribución de la intensidad luminosa sobre los puntos de un plano, siendo ésta una de las posibles representaciones de la información contenida en dicha imagen, en este caso en el dominio espacial. Existen, sin embargo, otras representaciones que contienen toda la información de la imagen, pero que no se definen en el dominio del espacio; tal es el caso de las representaciones en el dominio de la frecuencia, que expresan con qué periodicidad se repiten cierto patrones en una imagen, y que suponen un dominio alternativo de representación de esta información. Esta representación puede ser especialmente útil ya que teniendo la frecuencia de repetición de tales patrones se pueden detectar y alterar directamente elementos presentes en las imágenes como el ruido, los contornos o las texturas.

Para entender la utilidad de las representaciones en el dominio de la frecuencia, quizás lo más sencillo sea recurrir a un ejemplo monodimensional. En efecto, si se tuviese una señal acústica (representación temporal) compuesta de dos armónicos, por ejemplo correspondientes al sonido resultante de la mezcla de dos notas producidas por un piano, en el dominio de la frecuencia sería fácil aislar uno de ellos. Sólo habría que realizar la transformada de Fourier, localizar las dos frecuencias dominantes, calcular el término de la transformada de Fourier correspondiente a la nota que se desea eliminar, y hacer la transformada inversa, obteniendo la representación temporal correspondiente a una de las notas.

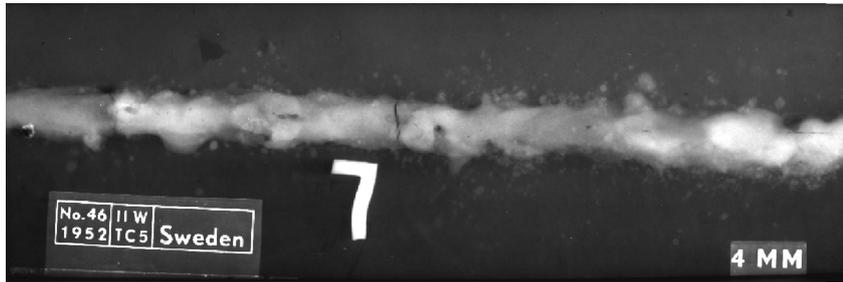
La misma idea sirve para eliminar el ruido de alta frecuencia existente en una señal. Si se sabe que una señal que contiene cierta información puede cambiar con una velocidad máxima, los cambios que se produzcan a una velocidad mayor corresponderán a ruido. Calculando la transformada de Fourier, eliminando los componentes correspondientes a las altas frecuencias y recuperando la señal mediante la transfor-



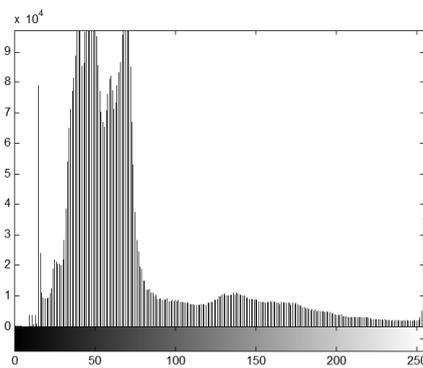
(a) Imagen original



(b) Histograma



(c) Imagen procesada



(d) Histograma

Figura 4.3: Resultado de la etapa de reducción de ruido mediante filtro Wiener.

mada inversa se obtiene la señal original sin el ruido. Este tipo de operación que elimina el ruido de alta frecuencia se conoce como filtrado paso bajo. Con un razonamiento similar es posible obtener sólo las componentes correspondientes a la alta frecuencia, en lo que se conoce como filtrado paso alto.

Con la formulación de la transformada de Fourier bidimensional para imágenes representadas en niveles de gris, es posible transformar una imagen del dominio del espacio al dominio de la frecuencia. Una vez en el dominio de la frecuencia, es sencillo realizar filtrados que eliminen elementos que aparezcan con cierto periodo.

El fundamento de las técnicas basadas en el dominio de la frecuencia es el teorema de convolución. Este teorema establece que si  $g(x, y)$  es la imagen formada por la convolución de la imagen  $f(x, y)$  y un operador lineal invariante  $h(x, y)$ , es decir

$$g(x, y) = h(x, y) * f(x, y) \quad (4.3)$$

entonces se verifica la siguiente relación en el dominio de la frecuencia

$$G(u, v) = H(u, v)F(u, v) \quad (4.4)$$

donde  $G, H$  y  $F$  son las transformadas de Fourier de  $g, h$  y  $f$  respectivamente.

Una vez calculado  $F(u, v)$  el objetivo es seleccionar  $H(u, v)$  de forma que la imagen obtenida

$$g(x, y) = \mathfrak{S}^{-1} [H(u, v)F(u, v)] \quad (4.5)$$

muestre algunos rasgos de interés de  $f(x, y)$ .  $h(x, y)$  caracteriza un sistema cuyo objetivo es producir una imagen transformada,  $g(x, y)$ , a partir de una imagen de entrada  $f(x, y)$ . En el dominio espacial, el sistema realiza la convolución de  $h(x, y)$  con la imagen de entrada y produce el resultado. El teorema de convolución permite dar una nueva interpretación al proceso, en el sentido de que se puede alcanzar el mismo resultado si trabajando en el dominio de la frecuencia, multiplicamos  $F(u, v)$  por  $H(u, v)$  para producir  $G(u, v)$ . Calculando la transformada inversa de Fourier de la salida se produce la imagen deseada.

El segundo algoritmo implementado en nuestro sistema para reducir ruido en las imágenes utiliza un filtro Gaussiano pasa-baja rotacional simétrico de tamaño  $3 \times 3$  con desviación estándar positiva [33]. Está representado en la figura 4.4, y se define mediante la siguiente formulación;

$$h_g(n_1, n_2) = e^{-(n_1^2 + n_2^2)/(2\sigma^2)}$$

$$h(n_1, n_2) = \frac{h_g(n_1, n_2)}{\sum_{n_1} \sum_{n_2} h_g} \quad (4.6)$$

Los bordes y otras transiciones bruscas en los niveles de gris de una imagen contribuyen significativamente en el contenido de alta frecuencia de la misma. Por tanto, el suavizado se consigue por sustitución de un rango específico de componentes de alta frecuencia en la transformación de la imagen dada.

El filtro Gaussiano pasa baja puede crear oscilaciones indeseadas que aparecen en la imagen filtrada, efecto conocido como *ringing*. Para evitar este efecto, aplicamos

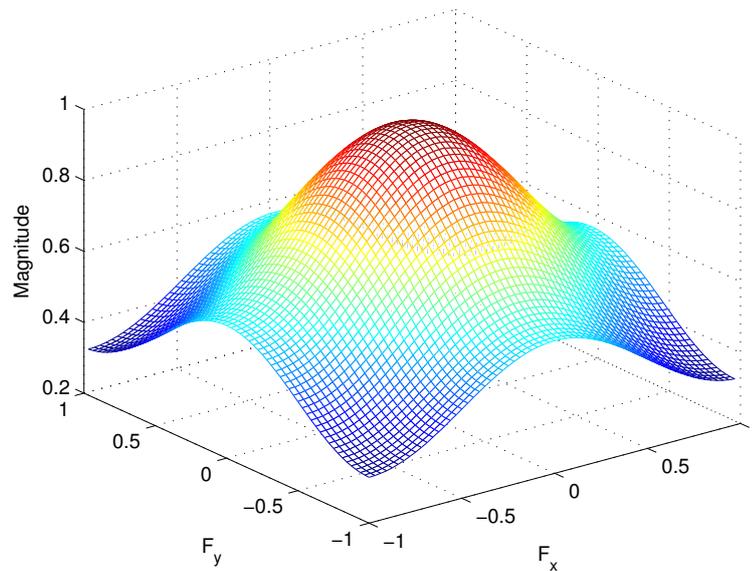


Figura 4.4: Respuesta frecuencial del filtro Gaussiano.

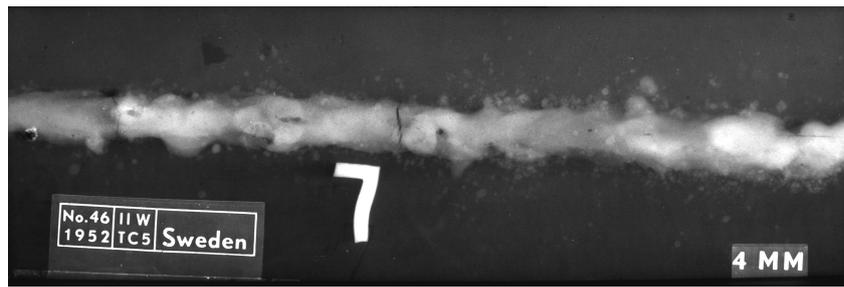
un algoritmo que elimina gradualmente la alta frecuencia en el borde de una imagen difuminando la imagen entera y reemplazando los píxeles centrales de la imagen difuminada con la imagen original. De esta forma, los bordes de la imagen decaen a frecuencias más bajas. La imagen resultado es la suma ponderada de la imagen original y su versión difuminada por la utilización del filtro Gaussiano.

Para ilustrar los resultados obtenidos con estas técnicas mostramos en la parte superior de la figura 4.5 la imagen de la radiografía original y en la parte inferior la imagen una vez aplicado un filtro Gaussiano y el algoritmo de reducción del efecto *ringing*, junto con los correspondientes histogramas. De nuevo los histogramas resultan más descriptivos del efecto de aplicación de la técnica que las imágenes en sí, apreciándose una gran similitud con el resultado de la aplicación del filtro Wiener para esta imagen.

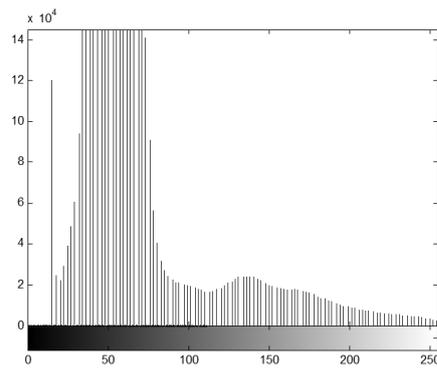
#### 4.2.2 Ajuste de Intensidades

Las técnicas de realzado y mejora de imágenes incluyen no sólo operaciones de reducción-eliminación de ruido, sino también operaciones que suponen modificaciones de los valores de intensidad de los píxeles. El ajuste de intensidades es una técnica de realzado que proyecta los valores de intensidad de una imagen en un nuevo rango. Para su estudio se requiere introducir los conceptos brillo y contraste, a partir del histograma.

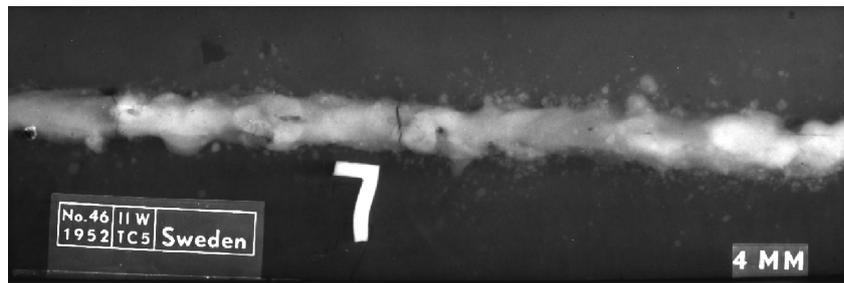
El histograma proporciona información estadística de la imagen, que puede resultar útil para conocer cómo se ha producido el proceso de su formación. Así, se define el brillo como el valor medio de la imagen que coincide con el del histograma:



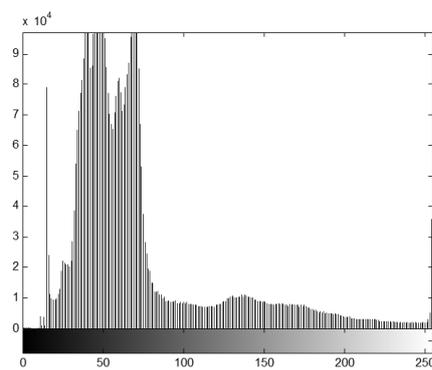
(a) Imagen original



(b) Histograma



(c) Imagen procesada



(d) Histograma

Figura 4.5: Resultado de la etapa de reducción de ruido mediante la aplicación de un filtro Gaussiano.

$$\text{Brillo} = \mu = \frac{1}{M \cdot N} \sum_{x=1}^M \sum_{y=1}^N f(x, y) = \sum_{i=0}^{I-1} i \cdot p(i) \quad (4.7)$$

donde  $f(x, y)$  representa el nivel de gris del píxel situado en las coordenadas  $(x, y)$ ,  $I$  es el número de niveles de gris que se ha empleado en el proceso de cuantificación de la imagen, y  $p(i)$  es la función de probabilidad de cada nivel de gris en la imagen.

Una imagen que presente un valor de brillo mayor que otra sobre la misma escena, se observa en el histograma como un desplazamiento neto hacia la derecha del eje de abscisa.

Así, en la figura 4.6 se representa dos sistemas distintos en cuanto a brillo, correspondiendo el histograma de la figura 4.6 (b) a un sistema de mayor brillo que la figura 4.6 (a).

Por otra parte, la varianza del histograma también se asocia al contraste de la imagen:

$$\begin{aligned} \text{Contraste} = \sigma^2 &= \frac{1}{M \cdot N} \sum_{x=1}^M \sum_{y=1}^N (f(x, y) - \mu)^2 \\ &= \sum_{i=0}^{I-1} (i - \mu)^2 \cdot h(i) = \sum_{i=0}^{I-1} (i - \mu)^2 \cdot p(i) \end{aligned} \quad (4.8)$$

El contraste representa la dispersión de los niveles de grises en la imagen. Aunque se pueden encontrar otras definiciones matemáticas del contraste, todas son medidas de dispersión. En todo caso, una imagen con poco contraste indica que hay poca variabilidad de los niveles de grises en la imagen. Su efecto se refleja en un histograma muy concentrado, o lo que es lo mismo, con un *rango dinámico* pequeño. En este contexto, se conoce como *rango dinámico* de una imagen al conjunto de todos los posibles valores de los píxeles que efectivamente se encuentran presentes en ella. Un valor pequeño (imágenes con poco contraste), da lugar a un empleo ineficiente de los recursos de captura como se muestra en la figura 4.7 (a). También puede darse el caso contrario, que ocurre cuando el histograma posee altos valores en los extremos de la escala, teniendo forma de  $U$ ; en este caso se dice que la imagen está saturada mostrado en la figura 4.7 (b).

El análisis del histograma de una imagen permite conocer detalles sobre la calidad de la misma y del proceso de captura que se ha utilizado para obtenerla. Así, las imágenes consideradas de calidad suelen tener un rango dinámico amplio y no saturado, conteniendo una mayor cantidad de información. También es importante para las tareas de reconocimiento que las imágenes tengan un alto nivel de contraste, ya que en este caso los detalles discriminantes se perciben con mayor claridad.

Por ejemplo, la imagen de la radiografía de una unión soldada como la de la figura 4.2 que venimos utilizando como patrón, podemos constatar que presenta un bajo contraste. En el histograma correspondiente se puede observar cómo los valores se concentran en un rango estrecho en torno al valor 50, de forma que existen relativamente pocos valores por debajo del nivel 20.

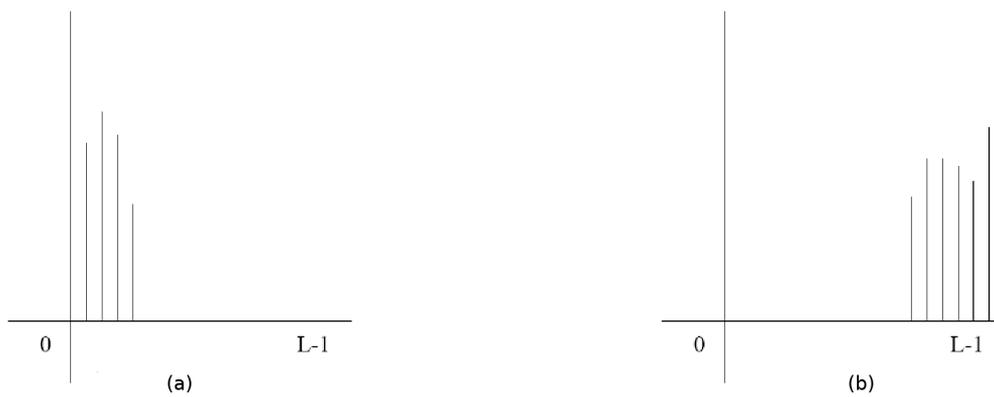


Figura 4.6: Ejemplos de histograma: (a) Bajo brillo; (b) Alto brillo.

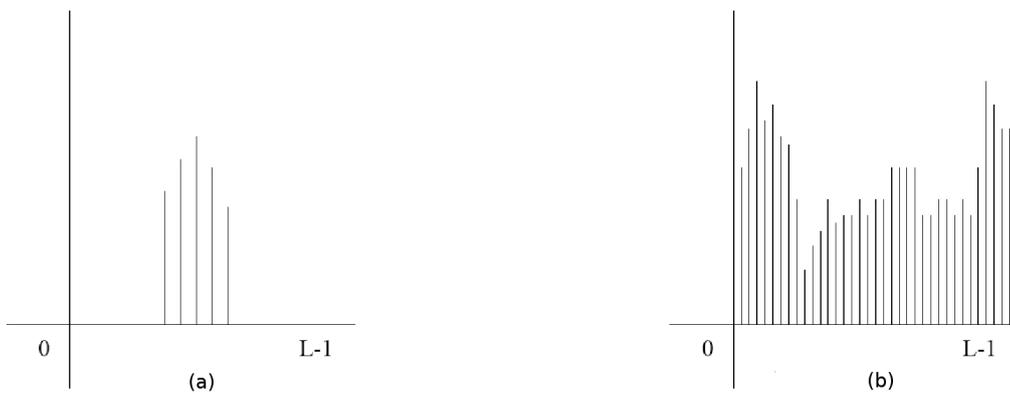


Figura 4.7: Ejemplos de histograma; (a) Bajo contraste; (b) Imagen saturada.

Si ajustamos los valores de intensidad de la imagen de forma que abarquen por completo el rango  $[0, 255]$ , podremos incrementar el contraste de la imagen. Para realizar estas operaciones debemos elegir los límites superior e inferior de la imagen y el rango donde queremos aplicarlos. La elección de dichos valores límites se realiza a partir del histograma de la imagen que queremos realizar.

Como consecuencia de lo comentado, en la segunda fase de la etapa de preprocesamiento de nuestro sistema de inspección de imágenes radiográficas de uniones soldadas implementamos un algoritmo para ajustar los valores de intensidad de la imagen utilizando el esquema descrito anteriormente. En este caso, el algoritmo proyecta los valores de intensidad de la imagen de partida a nuevos valores en una imagen transformada, de modo que los valores que representan los límites del histograma correspondientes al 1% y al 99% del total de las muestras se proyectan en el intervalo  $[0, 1]$ . Los valores de intensidad fuera de estos límites son desechados.

La figura 4.8 muestra la imagen ajustada con este algoritmo y su histograma, donde podemos comprobar el incremento de contraste de la imagen y cómo el his-

tograma ahora se extiende sobre todo el rango.

La correspondencia entre los valores en la entrada y la salida sigue, en este caso, una relación lineal, si bien se pueden especificar otros tipos de correspondencias no lineales mediante el uso de un factor de corrección  $\gamma$ . Este factor toma valores en el semieje positivo de los números reales. Si  $\gamma = 1$  particularizaremos al caso lineal, donde no se introduce modificación alguna sobre el histograma; si  $\gamma < 1$ , la transformación tiende hacia valores de salida más altos (más luminosos) produciendo un aclarado general de la imagen, si  $\gamma > 1$  el mapeo tiende a valores de salidas más bajos (más oscuros) produciendo un oscurecimiento general de la imagen. La figura 4.9 ilustra las curvas de transformación para valores de  $\gamma$  menor, igual, y mayor que 1. En todos los gráficos el eje  $x$  representa los valores de intensidad de la imagen de entrada, y el eje  $y$  representa los valores de intensidad de la imagen salida.

Como comentario final indicar que, una vez concluido el preprocesado de las radiografías, y con objeto de disponer de imágenes en tamaños más manejables desde el punto de vista computacional para abordar el resto de etapas que del sistema, la imagen resultado del preprocesado se divide en cinco bandas solapadas de  $640 \times 480$  píxeles, a lo largo del eje horizontal.

### 4.3 Segmentación del Cordón de Soldadura

En las técnicas de preprocesamiento aplicadas a las imágenes cada píxel se transforma de manera individual. Estos cambios, mayoritariamente, se realizan para facilitar la partición de la imagen en áreas o conjuntos de píxeles con algún significado.

En esta nueva fase, se trata de agrupar los píxeles por algún criterio de homogeneidad, para dividir la escena en regiones de interés con algún significado físico. Por tanto, la segmentación de una imagen es un proceso de extracción de objetos de interés insertados en la escena capturada. La agrupación de los píxeles para definir estos supuestos se realiza en base a criterios de similaridad entre vecinos, ya sea en valores de luminancia, pertenencia a bordes, texturas, etc.

Una vez que la imagen ha sido dividida en regiones, el análisis se desplazará del píxel individual a la agrupación de píxeles que constituye el objeto. La imagen se define ahora por un conjunto de objetos, habiendo pasado mediante un proceso de abstracción de un nivel bajo a otro más elaborado o nivel medio visual. La información estará ahora preparada para el reconocimiento e interpretación de la imagen.

Para la segmentación de las imágenes se usan tres conceptos básicos:

- Similitud: los píxeles agrupados del objeto deben ser similares respecto algún criterio (nivel de gris, color, borde, textura, ...).
- Conectividad: los objetos corresponden a áreas de píxeles con conectividad. Las particiones corresponden a regiones continuas de píxeles.
- Discontinuidad: los objetos tienen formas geométricas que definen unos contornos. Estos bordes delimitan unos objetos de otros.

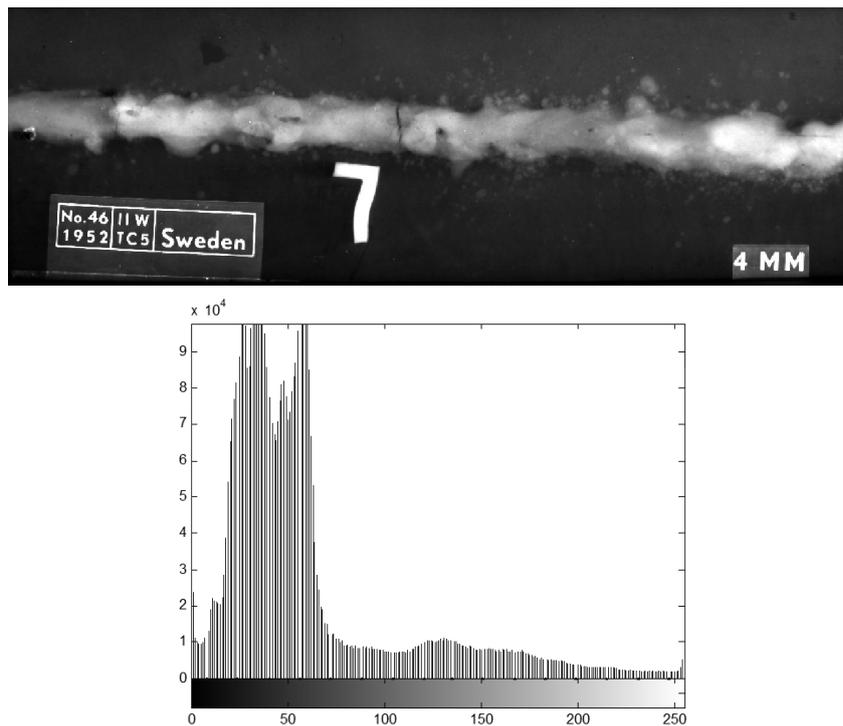


Figura 4.8: Resultado del ajuste de intensidad: arriba imagen procesada; abajo su histograma.

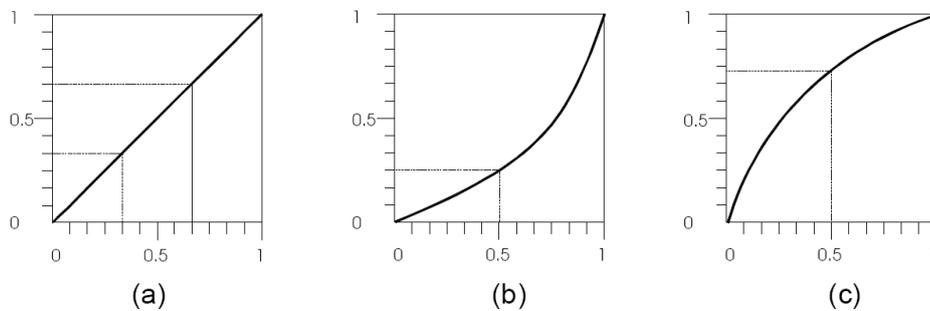


Figura 4.9: Transformaciones de histograma para (a)  $\gamma = 1$ ; (b)  $\gamma > 1$ ; (c)  $\gamma < 1$ .

En la práctica, estas condiciones, aparentemente claras en su formulación, quedan sometidas a factores que hacen que la segmentación no sea en absoluto un proceso sencillo. Respecto a la similitud, la aparición del ruido, presente en todas las imágenes, la falta de iluminación uniforme sobre el escenario o la creación de sombras de unos objetos sobre otros, dan lugar a que las reglas propuestas resulten en la práctica bastantes ineficaces cuando se aplican directamente sobre escenas más o menos complejas.

Por otra parte, la ocultación parcial de un objeto físico capturado hace fallar la conectividad del objeto virtual. En el proceso de segmentación se pueden obtener

múltiples regiones de píxeles agrupados que provienen del mismo objeto físico, no sólo debido a las propias oclusiones de éste, sino también a los cambios debidos a la textura del objeto, la variación de la iluminación de la escena o al reflejo de otros objetos físicos adyacentes.

Por último, la detección de los contornos físicos suele estar plagada de errores y de discontinuidades en los bordes. Resulta extraordinariamente difícil obtener los contornos cerrados, inmunes al ruido y sin desplazamiento entre el contorno real y el obtenido.

Dentro de las etapas que conforman un sistema de inspección de uniones soldadas, el proceso de segmentación del cordón de soldadura constituye una fase importante. En esta etapa, la finalidad es aislar el cordón de soldadura del resto de elementos que componen la imagen radiográfica de la unión soldada, con lo que conseguimos encuadrar la escena de interés para facilitar las tareas posteriores de detección y clasificación de posibles defectos.

Para este objetivo pueden utilizarse diferentes tipos de técnicas de procesamiento o *especialistas*, dirigidas a la búsqueda de discontinuidades (puntos, líneas y bordes) en la imagen. Sin embargo, el tipo de imágenes de nuestra aplicación presenta una serie de peculiaridades que llevan a que las técnicas genéricas de procesamiento de imágenes proporcionen resultados muy pobres cuando son utilizadas individualmente para segmentar el cordón de soldadura en todos los tipos de radiografías de uniones soldadas. La fiabilidad del proceso de segmentación dependerá, más bien, de la aplicación de secuencias adecuadas de estos especialistas a partir del conocimiento de los modelos de objetos que pretendemos detectar (conocimiento del dominio).

Para solucionar los problemas presentados por las técnicas de segmentación-detección de cordones de soldadura propuestas en la literatura y revisadas en el capítulo 2 de esta memoria, es preciso recurrir al conocimiento que disponemos sobre radiografías de uniones soldadas. Hemos desarrollado e implementado tres propuestas en este sentido. La primera se basa en el intento de superar los inconvenientes observados en la utilización de técnicas de umbralización, con la inyección de conocimiento previo del dominio; a esta propuesta la hemos denominado *técnica de segmentación basada en perfiles* [96] y [97]. La segunda propuesta, al igual que la anterior, recurre a la información proporcionada por la radiografía para llevar a cabo su análisis. Básicamente, esta técnica realiza sucesivas segmentaciones sobre la imagen para, tras una fase de eliminación de contornos, aislar el cordón de soldadura; a esta propuesta se le ha denominado *técnica de segmentación progresiva* [95]. La última de las propuestas utiliza técnicas de umbralización óptima y etiquetado de regiones para finalmente, a través de un criterio de selección, delimitar la región que constituye el cordón de soldadura [98] y [108]; a esta tercera propuesta la hemos denominado *técnica de segmentación basada en etiquetado de componentes conectados*.

A continuación, se describen de forma detallada cada una de las propuestas para esta etapa del sistema.

#### 4.3.1 Técnica de Segmentación Basada en Perfiles

En esencia, la técnica utiliza información local suministrada por perfiles aplicados sobre la imagen radiográfica. Un perfil no es más que una representación de los

niveles de gris de los puntos incluidos a lo largo del segmento lineal trazado sobre la imagen. En la figura 4.10 se ilustra el aspecto de un perfil trazado sobre una imagen de una unión soldada de 480 píxeles de longitud, a lo largo de un segmento perpendicular al eje longitudinal de unión. En este tipo de imágenes, un umbral fijo nunca producirá una segmentación satisfactoria, por lo que dicha segmentación deberá ser abordada mediante la aplicación de técnicas de umbralización adaptativa, en las que la imagen se divide en zonas no solapadas, calculándose para cada una de ellas su umbral correspondiente extraído de la información de los perfiles de cada una de estas zonas.

El proceso se realiza en dos fases. En una primera fase se llevan a cabo operaciones de búsqueda del umbral óptimo para detectar en la imagen de la unión soldada la zona que se corresponde con el soporte radiográfico, para en una segunda fase encaminar dicha búsqueda a la segmentación del cordón de soldadura. En ambas etapas se emplea, de forma explícita, conocimiento del dominio, tanto para establecer los criterios de búsqueda de los niveles de umbral como para realizar el refinado de las posiciones encontradas cuando éstas se sitúan en localizaciones imposibles. A continuación se describe brevemente el proceso.

#### 1º fase. Segmentación de la escena de interés.

El objetivo de esta primera fase es la localización en la imagen radiográfica de la zona ocupada por el soporte radiográfico. Dicha zona carece de interés para posteriores etapas y, por contra, incrementa de forma considerable el tiempo de computación

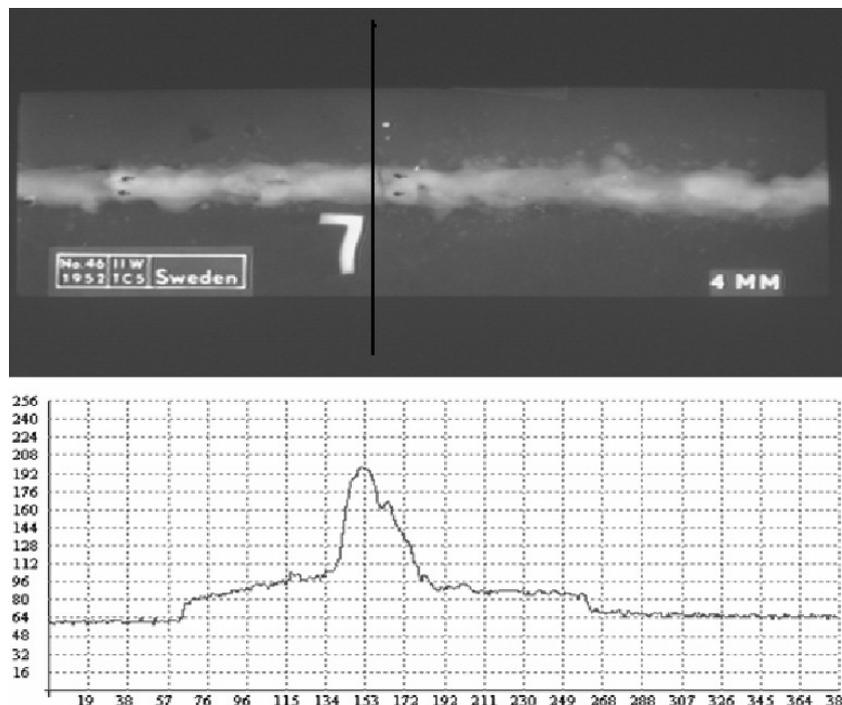


Figura 4.10: Segmentación basada en perfiles: ejemplo de extracción de un perfil.

de cualquier operación sobre la imagen. Es lógico pensar, en consecuencia, que las posteriores operaciones, éstas han de resultar menos complicadas si se reduce la zona de búsqueda del posible cordón de soldadura; de ahí la necesidad de eliminar la zona correspondiente al soporte radiográfico.

La segmentación se lleva a cabo mediante un algoritmo de búsqueda de las posiciones donde se producen variaciones significativas de los niveles de gris, que deben corresponderse con la frontera entre el soporte radiográfico y el metal base; el cordón de soldadura es una región eminentemente clara, mientras que sus alrededores van a ser oscuros.

El proceso se realiza en tres etapas, como se aprecia en la figura 4.11. En una primera etapa se procede a calcular los perfiles de la imagen desde la posición vertical (0) hasta la (480) en las 640 localizaciones posibles, para, en cada uno de dichos perfiles, localizar las posiciones donde se producen variaciones en los niveles de gris superiores al 3% entre píxeles separados dos posiciones en el perfil. En el caso de no existir dicha variación, o que su localización se dé en una posición imposible, se sitúa la frontera de ese perfil en una posición predeterminada en función del conocimiento previo de las condiciones de adquisición de la imagen y de las dimensiones usuales de las superficies de visualización de los negatoscopios.

En una segunda etapa dividimos la imagen en 64 bandas de 10 píxeles de anchura, calculando para cada banda la media de las posiciones encontradas en la etapa anterior,  $media_1$ . Para cada una de las 64 bandas segmentamos la imagen con un valor de umbral igual a  $media_1$ . El proceso se esquematiza de forma gráfica en la figura 4.12

Para finalizar, en una tercera etapa, y en previsión de falsas detecciones de la frontera entre el soporte radiográfico y el metal base, se realiza un refinado de la segmentación inicial, de forma que, si la localización de la frontera en cada perfil difiere en exceso de la media de la zona a la que pertenece, adopte como posición de segmentación la posición encontrada en el perfil inmediato anterior.

## 2º fase. Segmentación del cordón de soldadura.

El objetivo de esta segunda fase es aislar, en la imagen obtenida en la fase anterior, la zona correspondiente al cordón de soldadura. En esta zona es donde se localizan los posibles defectos que posteriormente serán detectados y evaluados en una unión soldada, por lo que resulta de gran importancia delimitarla y separarla del resto de objetos que forman la imagen radiográfica. El esquema se muestra en la figura 4.13.

Para ello, calculamos los perfiles en una franja localizada, de manera automática, en una zona de la imagen libre de marcas de identificación, o bien en una posición y con una anchura decidida por el usuario o *zona muestral*. Para cada perfil calculado en la zona muestral, buscamos variaciones en el nivel de gris superiores al 3% entre píxeles separados dos posiciones en el perfil, iniciando la búsqueda desde la posición donde se situó el valor  $media_1$ . En el caso de no existir dicha variación o localizarla en una posición imposible de ubicación del borde superior del cordón, se inicia la búsqueda de variaciones de niveles de gris entre píxeles separados cinco posiciones

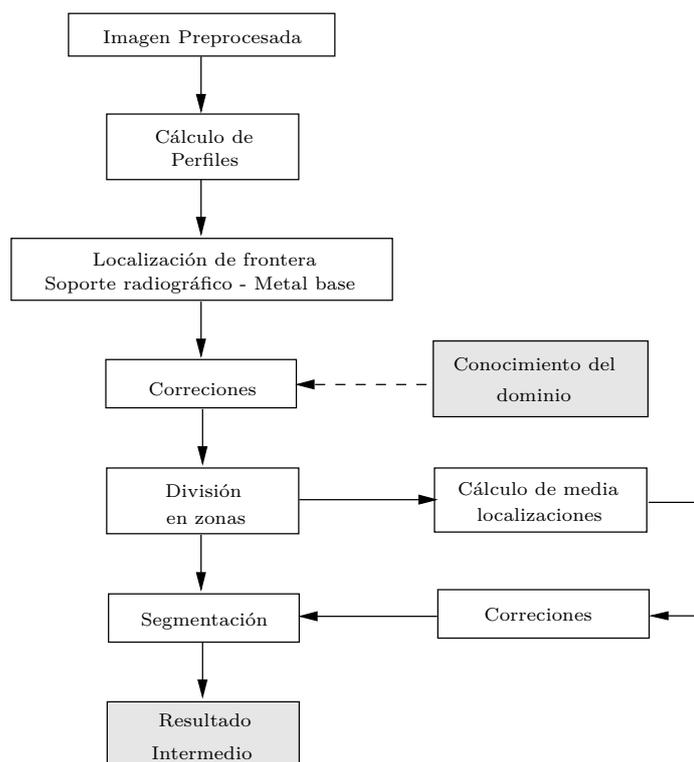


Figura 4.11: Algoritmo de segmentación basada en perfiles: esquema de la 1ª fase.

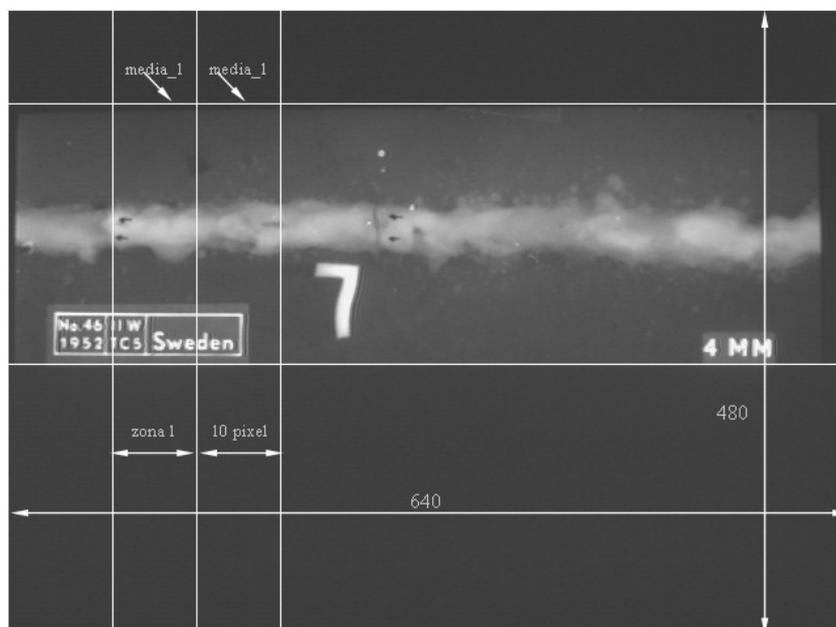


Figura 4.12: División de la zona de interés en bandas.

en el perfil. De todas las localizaciones positivas se extrae la media muestral que llamaremos  $media_2$ .

A continuación, sobre los 640 perfiles de la imagen, y a partir de la posición de la media muestral calculada,  $media_2$ , se inicia la búsqueda de variaciones de nivel de gris superiores al 3% cada 3 píxeles consecutivos. Si localizado este salto se encontrara muy alejado del valor de  $media_2$ , se iniciará la búsqueda para píxeles separados 5 posiciones. De persistir esta situación, se adoptará el valor hallado para el perfil anterior.

Finalmente, y para cada perfil, se segmenta la imagen utilizando como nivel de umbral el nivel de gris de las posiciones encontradas en cada uno de los perfiles. El procesamiento de esta fase se ilustra en la imagen radiográfica de la figura 4.14.

Por último, y para refinar el resultado de la segmentación obtenida en la fase anterior, se realiza una operación de *slicing zonal* sobre 64 zonas de 10 píxeles de amplitud, manejando como criterio de posición de inicio de la segmentación la localización más baja de cada zona obtenida en la fase anterior, y como valor de umbral la media de los niveles de gris de dichas localizaciones. Esta operación fija un valor de nivel de gris determinado para los píxeles comprendidos entre dos niveles de gris elegidos por el usuario, quedando los restantes valores a su nivel original.

Un ejemplo del resultado de la aplicación de este procedimiento sobre la imagen radiográfica utilizada como patrón se muestra en la figura 4.15.

### 4.3.2 Técnica de Segmentación Progresiva

Una segunda propuesta para conseguir la delimitación del cordón de soldadura asume el marco formal de interpretación de imágenes basadas en conocimiento [90]. Los sistemas de visión basados en conocimiento emplean conocimiento del dominio para analizar las imágenes, conocimiento que puede ser muy general o extremadamente específico. En este tipo de aproximaciones se inyecta conocimiento explícito para obtener la interpretación global de la imagen.

La estrategia de control de un sistema dictamina cómo será usado el conocimiento en dicho sistema. El *control jerárquico* es la estructura más común y está definida mediante una jerarquía predefinida u orden de los procedimientos que realizan la tarea de análisis requerida. En su forma más usual, un procedimiento principal llama a un conjunto de rutinas de preprocesado que transforman la imagen original en otro formato más adecuado para extraer las propiedades primitivas. A continuación, una rutina de extracción de propiedades localiza las de interés y construye una descripción simbólica de estas propiedades y sus relaciones. Finalmente, un procedimiento de toma de decisiones relaciona algún tipo de tarea de reconocimiento empleando la descripción simbólica. Cada uno de estos procedimientos tiene su propia tarea y su propia posición en la jerarquía y se comunican entre sí sólo a través de resultados intermedios.

Existen dos clases principales de control jerárquico: *bottom-up* y *top-down*. El control *bottom-up* sigue el guión antes descrito; se extraen propiedades de la imagen y se agrupan de alguna forma, sin conocimiento de la estructura del objeto o escena.

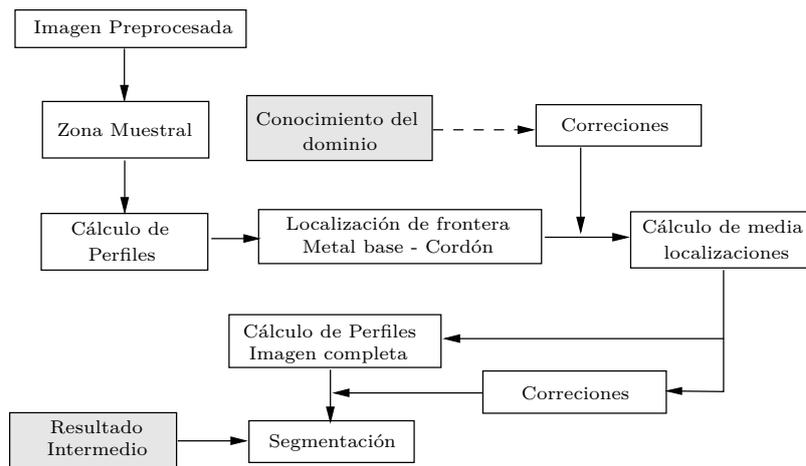


Figura 4.13: Algoritmo de segmentación basada en perfiles: esquema de la 2ª fase.

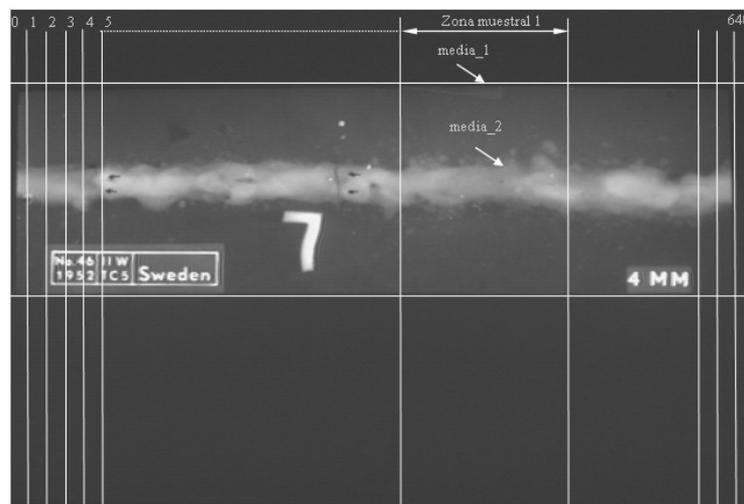


Figura 4.14: Aplicación de la 2ª fase de segmentación basada en perfiles sobre la imagen ejemplo.

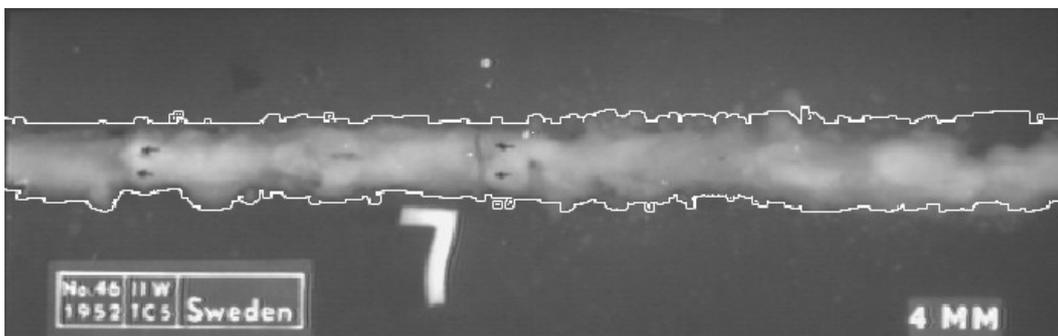


Figura 4.15: Resultado de la segmentación del cordón de soldadura mediante la técnica basada en perfiles.

Sólo después de que se construye una descripción simbólica completa se emplean los modelos del objeto o escena en un procedimiento de detección. El control *top-down* comienza con una hipótesis acerca de que la imagen contenga un objeto particular o que pueda catalogarse como un tipo de escena particular, lo que conduce a más hipótesis sobre las partes del objeto o escena que pueden estar presentes. Estas hipótesis llevan a expectativas de ciertos tipos de primitivas en ciertas relaciones. Eventualmente, las rutinas de extracción de propiedades se pueden invocar, bien para verificar la existencia de una primitiva y notificar su localización, o bien para notificar un fallo.

Ni el control *bottom-up* ni el *top-down* son suficientemente flexibles para el análisis de imágenes complejas. Una variante más potente es el *control híbrido con retoalimentación*. En esta aproximación se comienza con una segmentación inicial de la imagen y la extracción de un conjunto preliminar de propiedades y relaciones. Basándose en esta descripción preliminar, se realiza una hipótesis sobre la identidad de uno o más objetos, y a continuación se puede usar una estrategia *top-down* para verificar o rechazar la existencia de estos objetos. El conocimiento de los objetos verificados y de la case de escena permite generar nuevas hipótesis. Además, como se han reconocido objetos o partes de ellos, se puede deducir más información que ayudará en el proceso global de reconocimiento.

La segunda técnica propuesta para el reconocimiento del cordón de soldadura en imágenes radiográficas de uniones soldadas realiza el proceso de análisis en tres niveles. En el nivel más bajo se realizan operaciones sobre la imagen independientes del conocimiento del dominio; éste se utiliza de manera implícita en el nivel intermedio y de forma explícita en la última fase o de alto nivel.

En cuanto a la estructura de control, puede entenderse, por una parte, como *bottom-up* (dirigida por datos). Partimos de una imagen de radiografía sobre la que se realizan diversas operaciones, obteniendo imágenes intermedias hasta alcanzar una imagen final en la que únicamente aparece el cordón de soldadura. Pero éste no es el único tipo de control, dado que en la última parte del sistema se hace uso del control híbrido, en el que el flujo viene determinado por el tipo de región que se está buscando; el control se rige por las características de la imagen de cara a la identificación del contorno del cordón de soldadura.

Los tres niveles anteriores de procesado están conectados entre sí a través de una *Base de Datos*. En esta base se almacenan los distintos resultados intermedios, que son imágenes sobre las que se realizan operaciones diversas, como etiquetados, obtención de contornos o eliminación de información no necesaria, además de la imagen original, y donde finalmente se guardará la imagen resultado con el cordón de soldadura aislado.

El esquema general de bloques del sistema se ilustra en la figura 4.16, y en los siguientes subapartados describiremos de forma más detallada cada uno de los módulos.

### Bloque de bajo nivel

El objetivo del bloque de bajo nivel es segmentar la imagen en un conjunto de regiones elementales homogéneas. Aun cuando estas regiones no coincidirán necesari-

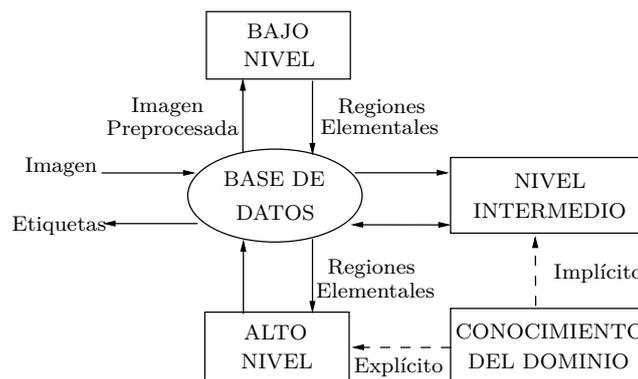


Figura 4.16: Esquema general de la segmentación progresiva.

riamente con regiones significativas, sí que constituirán los elementos para la interpretación de la escena.

En este bloque se realizan dos segmentaciones sucesivas de la imagen. Con la primera se pretende dividir la imagen original en diversas regiones elementales. Esta segmentación no se realiza de forma estricta, esto es, no se pretende alcanzar un alto grado de detalle que identifique inicialmente la zona correspondiente con el cordón de soldadura, sino tan sólo separar las zonas que presentan información de interés de las zonas que carecen de esta información relevante. Mediante la segunda segmentación, realizada sobre la imagen de contornos obtenida de la primera, se consigue sobre-segmentar las regiones catalogadas como claras, pues entre éstas se encontrará el cordón de soldadura. En ambas segmentaciones hemos empleado una técnica en la que para definir los centroides locales se emplea información estadística de la imagen (histograma), de forma que se realiza una división iterativa de dicho histograma basada en el análisis de los centros locales de clusterización [68], [106] y [9]. El esquema del proceso que se sigue en este primer bloque se resume en la figura 4.17.

Según el esquema adoptado, el problema de la segmentación del cordón de soldadura se convierte en un problema de clusterización del histograma. Para resolverlo hemos hecho uso del algoritmo de clusterización propuesto por Carreira [9], que siguiendo un procedimiento iterativo realiza una búsqueda de los centros de clases en el histograma, basándose en la definición de centroides locales junto a un desplazamiento de las masas de probabilidad hacia dichos centroides [68]. Este algoritmo es una generalización del propuesto previamente por Wilson y Spann [106], que proponen un esquema iterativo en un único nivel, de forma que el número de clases finales depende del tamaño de la ventana y de la cantidad de máximos locales del histograma original. La dependencia del tamaño de la ventana lo resuelven los autores aumentando después de cada iteración el tamaño de la ventana en cinco unidades, y aceptándolo cuando los resultados sean consistentes. Este esquema lo mejora Carreira eliminando la dependencia con el tamaño de la ventana mediante un segundo proceso iterativo que calcula el tamaño de la ventana óptima, a la vez que reduce la dependencia respecto al número de máximos locales del histograma original preservando, en cada iteración, los resultados de las ventanas menores.

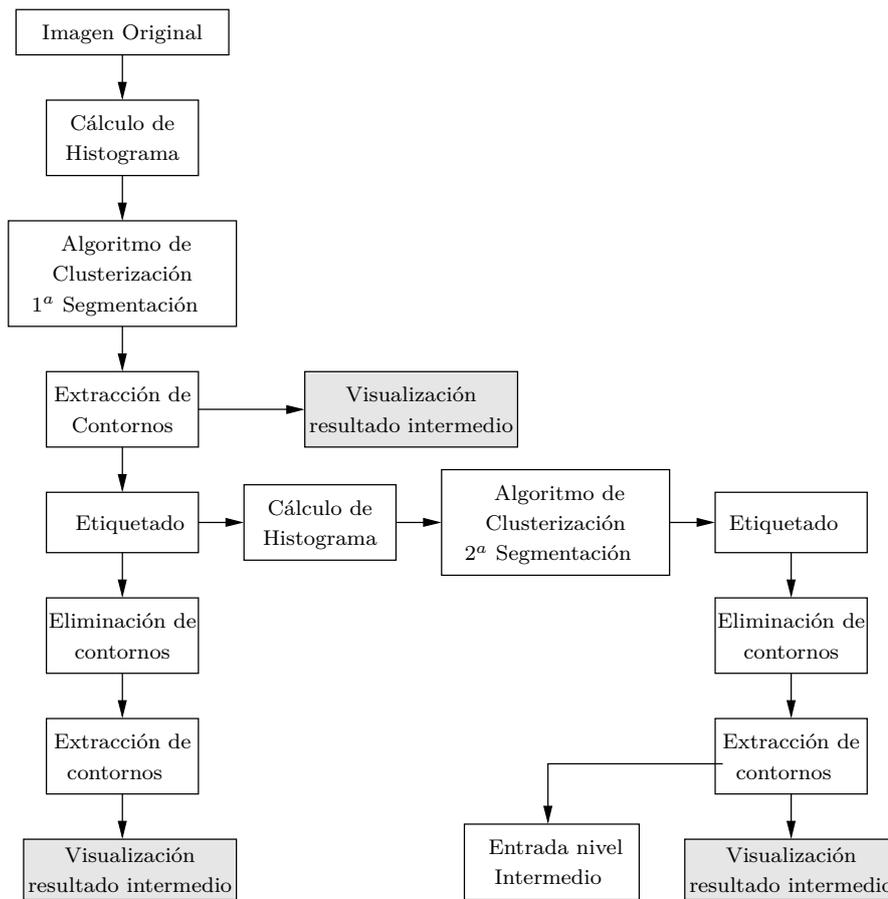


Figura 4.17: Esquema del bloque de bajo nivel de la segmentación Progresiva

La clasificación final de los píxeles se realiza asociando a cada píxel con el centro de cluster más cercano, calculando para ello la distancia *city-block*. La distancia *city-block* entre dos píxeles,  $p(x, y)$  y  $q(s, t)$ , se define como:  $D_4(p, q) = |x - s| + |y - t|$  donde las coordenadas se refieren al espacio de propiedades.

Para tener en cuenta en la segmentación tanto la información global del espacio de propiedades como la organización espacial de estos datos en el espacio de la imagen, de las regiones que se obtienen se eliminarán aquellas cuyo tamaño sea excesivamente pequeño. En concreto se eliminarán las regiones cuyo tamaño sea menor del  $100/(1,5 \times NL)\%$  del número total de píxeles, siendo  $NL$  el número de clases.

Para la segmentación inicial se parte de la información estadística que nos ofrece el histograma de la imagen original, y requiere evaluar un parámetro denominado porcentaje mínimo de histograma, que expresa el tamaño mínimo que ha de tener un *cluster* para ser considerado región. La elección de este parámetro nos permite determinar el grado de detalle de la segmentación, y puesto que el objetivo de esta primera segmentación es delimitar las zonas de interés, un valor adecuado de dicho parámetro estará en torno a 10. Así, la primera segmentación nos da como resultado una imagen poco segmentada, normalmente dos regiones, que coincidirán

con el soporte radiográfico y la zona ocupada por el metal base que incluye al propio cordón de soldadura.

Para la segunda de las segmentaciones que se realiza en este primer bloque se utiliza el mismo algoritmo, pero en este caso el parámetro que regula el grado de segmentación es el *intervalo mínimo entre centros de clusters* adyacentes, que mide la distancia mínima que deberá existir entre centros de *clusters* contiguos para ser considerados como región. La influencia de este parámetro en el número final de regiones detectadas queda reflejada en la figura 4.18. Cuanto mayor sea el intervalo considerado, menor será el número de regiones obtenidas en la segmentación. Dado que el cordón de soldadura se situará entre las regiones claras del histograma, interesará que para éstas el valor del parámetro sea bajo, en torno al 8 %, mientras que para regiones catalogadas como oscuras se elegirá un valor alto, en torno al 20 %.

Realizada la primera segmentación sobre la imagen original, a continuación se lleva a cabo una operación de extracción de contornos con un doble objetivo: por un lado visualizar el resultado obtenido, y por otro lado servir como entrada a la fase de etiquetado de las regiones detectadas.

El etiquetado es básicamente un proceso de crecimiento de regiones en el que se introduce un parámetro de restricción (*tamaño mínimo de región*) con el que evitamos que regiones excesivamente pequeñas o píxeles aislados sean considerados como regiones. Este proceso de etiquetado se repite en la imagen obtenida tras la segunda segmentación.

La influencia del parámetro *tamaño mínimo de región* en el número final de regiones detectadas tras el proceso de eliminación de contornos se ilustra en la Figura 4.19. En cuanto a la elección del valor idóneo para este parámetro, dependerá de la etapa donde lo apliquemos. Así, para la primera segmentación, en la que interesa un tamaño de regiones suficientemente grande, se adoptará como valor el 0.1 % del tamaño de la imagen ( $480 \times 640$ ), mientras que tras la segunda segmentación el valor del parámetro será del 0.02 %.

En suma, el resultado de este primer bloque es una imagen segmentada en un gran número de regiones y en donde en el cordón de soldadura se habrán generado multiplicidad de contornos debido a transiciones suaves de niveles de gris.

### **Bloque de nivel intermedio**

La segunda fase, o bloque de nivel intermedio, tiene como objetivo el refinamiento de la segmentación obtenida en el bloque anterior, confirmando o no la presencia de contornos, para lo cual emplea información espacial obtenida en el plano de la imagen y que se plasma en la utilización de parámetros que controlan el proceso [11]. En la figura 4.20 se muestra el esquema de tareas del proceso seguido en este bloque.

La idea de segmentación planteada responde a un esquema de *segmentación progresiva* [91] en el que una segmentación inicial es refinada usando de forma progresiva conocimiento del dominio. Así, en nuestro caso, una imagen sobresegmentada en base a información estadística es refinada usando información espacial para confirmar que los contornos extraídos son realmente contornos significativos. Estos contornos

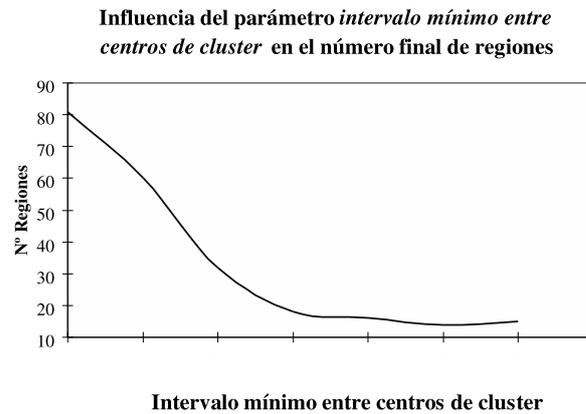


Figura 4.18: Influencia del parámetro *intervalo mínimo entre centros* en el número final de regiones.

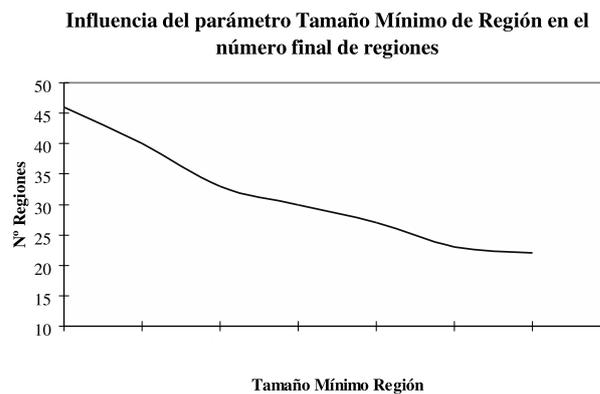


Figura 4.19: Influencia del parámetro *tamaño mínimo de región* en el número final de regiones.

son modificados o eliminados en base a criterios que incluyen de una forma implícita conocimiento del dominio.

Siendo más concretos, la imagen de contornos obtenida en el bloque de bajo nivel es sometida a un proceso de codificación de vértices para facilitar las operaciones posteriores. Esta codificación se realiza sobre la base de un orden de los vértices que va del 1 al 4, considerando las cuatro direcciones principales, de forma que serán considerados como vértices de orden 1 aquéllos de comienzo o fin de contorno, los de orden 2 son los de continuación de contorno y los de orden 3 y 4 aquéllos que constituyan puntos de cruce de tres o cuatro contornos, respectivamente.

Tras el proceso de codificación de vértices, y con el objetivo de depurar los contornos detectados, se procede al *limado* de los mismos, de forma que éstos puedan seguirse, a partir de un vértice de comienzo, de forma única hasta su final, salvo en

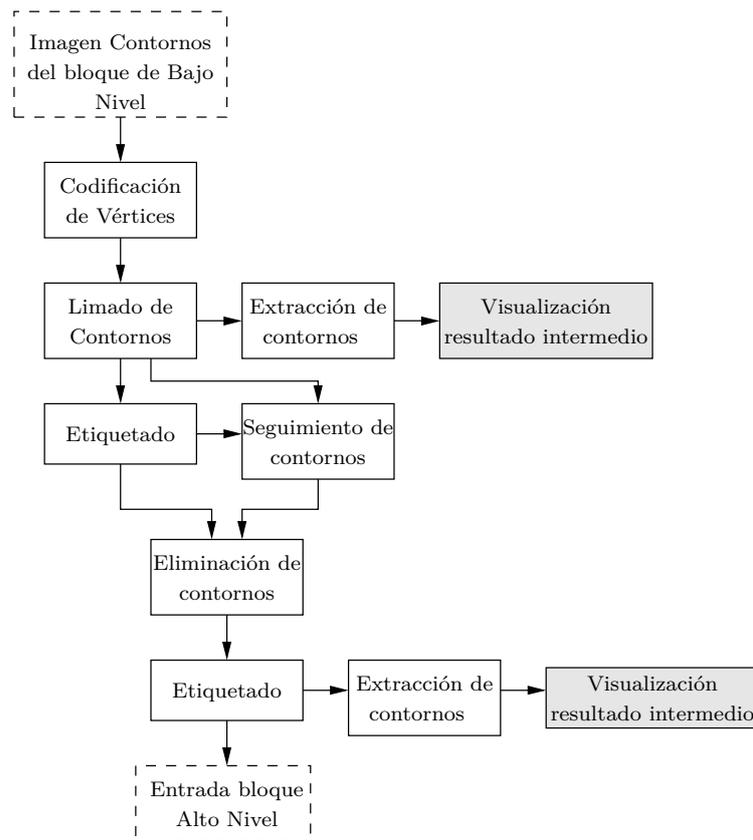


Figura 4.20: Esquema del bloque intermedio de la segmentación progresiva.

los puntos de cruce entre contornos. Las situaciones a las que se aplicará el limado se pueden ver en la figura 4.21, donde se observan vértices de orden 1, 2 y 3 y en la que los vértices rodeados por un círculo serán eliminados, excepto en el último caso, en el que se intentará mover alguno de los vértices de orden 3 hacia alguna posición libre en sus alrededores.

Una vez realizado el limado, la imagen obtenida está preparada para el seguimiento de los contornos, que dará lugar a la elaboración de la matriz de propiedades de los contornos codificados. Ésta es una matriz de dimensión *número contornos*  $\times$  *longitud máxima*, donde se almacenan cada uno de los contornos etiquetados y la longitud de los mismos, y que nos permitirá para cada píxel conocer a qué contorno pertenece y su localización dentro del mismo [10].

El esquema de bloques del algoritmo de seguimiento de contornos utilizado se muestra en la figura 4.22, donde  $k$  representa la etiqueta de cada contorno,  $l$  la posición de cada punto dentro de él,  $long(k)$  es la longitud del mismo y  $\mathbf{B}$  una la matriz donde se almacenan las coordenadas de cada punto de dicho contorno.

Obtenida la matriz de propiedades, se realiza el proceso de refinado de la segmentación inicial, determinando si los contornos obtenidos se eliminan, se modifican o se mantienen. En este proceso se deben penalizar los contornos paralelos estable-

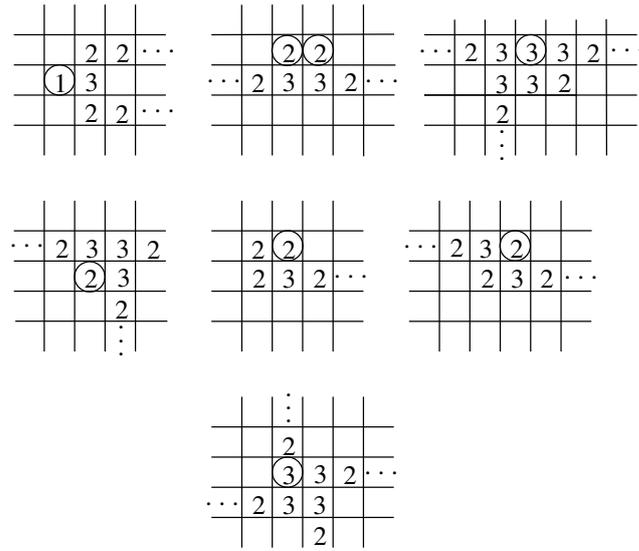


Figura 4.21: Ejemplos del proceso de limado de contornos.

ciendo, siempre que sea posible, un contorno único en el área de mayor contraste. El procedimiento de refinado consiste en calcular una *función de mérito* para cada contorno donde se engloben criterios de contraste, longitud e información adyacente, eliminando aquellos contornos con función de mérito pequeñas [10]. De esta manera, para cada contorno  $b_k$ , que separe dos regiones  $R_i$  y  $R_j$ , se define una función de mérito  $fm(b_k)$ :

$$fm(b_k) = |vmg(R_i) - vmg(R_j)| \tag{4.9}$$

representando la función  $vmg()$  el valor medio de gris de una región. La función de mérito representa la fuerza de un contorno visto como borde. En un principio los contornos con función de mérito pequeña serán eliminados.

Un problema que puede aparecer al realizar la eliminación de contornos es que pueden introducirse modificaciones topológicas que en la realidad no existen. Por ejemplo, si nos fijamos en la figura 4.23 vemos que existen tres regiones;  $R_1$ ,  $R_2$  y  $R_3$ , y cuatro contornos  $b_1$ ,  $b_2$ ,  $b_3$  y  $b_4$ . El problema ocurre en este caso al eliminar el contorno  $b_1$ ; si esto se hace se debería eliminar  $b_2$ , puesto que este contorno ya no separa dos regiones distintas. De igual forma, si se elimina  $b_3$  los contornos  $b_1$ ,  $b_4$  y  $b_2$  se unen para formar un único contorno entre las regiones  $R_3$  y  $R_1 + R_2$ , y por tanto ya no se podrán eliminar  $b_1$ ,  $b_2$  ó  $b_4$ . Al primer caso se le denomina *restricción de regiones* y al segundo *restricción de contornos*.

En vez de decidir de forma local si un contorno se elimina, se define una función de mérito global que ha de maximizarse y que se expresa en términos de la función de mérito local  $fm(b)$ . Se procederá de la manera siguiente: si un contorno va a ser eliminado contribuye a la suma con  $\theta - fm(b_i)$ , siendo  $\theta$  un valor de umbral de contraste; si por el contrario el contorno se conserva, contribuye con  $fm(b_i) - \theta$ . Si  $I_c$  e  $I_e$  son los conjuntos de índices para los dos grupos de contornos (c: conservados, e: eliminados), entonces la función de mérito global,  $F$ , se puede definir de la forma:

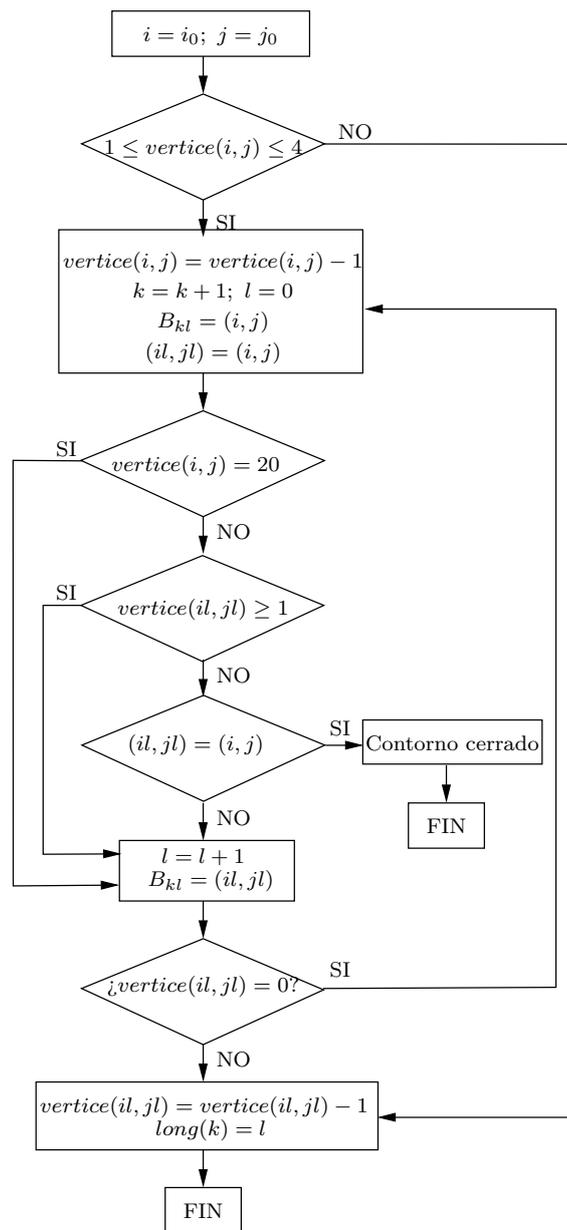


Figura 4.22: Algoritmo de seguimiento de contornos.

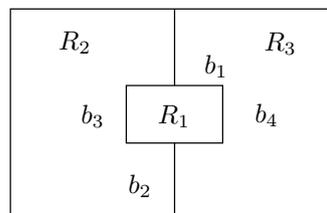


Figura 4.23: Ejemplo de restricciones topológicas.

$$F(b_1, b_2, \dots, b_n) = \sum_{i \in I_e} (\theta - fm(b_i)) + \sum_{i \in I_c} (fm(b_i) - \theta) \quad (4.10)$$

El valor de  $\theta$  es uno de los parámetros que controlan el proceso de refinado y se debe elegir como el contraste esperado a través de los bordes de la imagen. Si en un principio ignoramos las restricciones topológicas, entonces para un  $\theta$  dado la función  $F()$  será máxima si eliminamos todos los contornos con  $fm$  menor que  $\theta$  y mantenemos los demás. Pero como se dijo anteriormente la eliminación de contornos, a pesar de que tengan una función de mérito pequeña, puede dar lugar resultados incorrectos. Por tanto, para mantener la validez topológica debemos de conservar algunos contornos, que pese a ser eliminables en cuanto a función de mérito permiten mantener la coherencia topológica.

El proceso de decidir si un contorno candidato a ser eliminado en términos de su función de mérito, puede eliminarse realmente sin violar las restricciones topológicas, no puede conllevar un análisis exhaustivo de todas las combinaciones de configuraciones de contornos válidos topológicamente, ya que supone un gasto computacional muy elevado. Una buena solución es la propuesta por Carreira [9], consistente en elegir un algoritmo *avaro*, es decir, se eliminarán sucesivamente aquellos contornos cuya función de mérito sea menor que el umbral  $\theta$ , hasta que no existan contornos que verifiquen esta condición. Este proceso puede ser modificado prediciendo el efecto sobre  $F()$ . En efecto, si un contorno es inicialmente eliminado deberemos comprobar si su efecto no es deseable, en cuyo caso el contorno no se eliminará. La procedencia o no de eliminar un contorno se estimará a partir de la reestructuración de la imagen al unir las regiones que separaba el contorno, y tras la reorganización de la configuración de los contornos. Si durante el proceso se unen contornos con valores muy distintos de sus funciones de mérito, entonces se cancela la eliminación del contorno. El proceso completo se recoge en el algoritmo 1.

---

**Algoritmo 1** Algoritmo de Eliminación de Contornos

---

```

mientras  $flag = \text{VERDAD}$  hacer
  Repetir PASOS 2 a 6
   $f_{min} = \theta; flag = \text{falso}$ 
  Para todos los contornos  $b_i$ , realizar el PASO 4
  si  $fm(b_i) < f_{min}$  Y  $better(b_i) = \text{VERDAD}$  entonces
     $f_{min} = fm(b_i)$ 
     $i_{min} = i$ 
     $flag = \text{VERDAD}$ 
  si no  $\{f_{min} \geq \theta\}$ 
    Ir al PASO 7
  Eliminar  $b_{i_{min}}$  y reorganizar la lista de contornos
  fin si
fin mientras

```

---

Dentro del algoritmo nos encontramos con la función  $better()$ , cuya operación se describe en el algoritmo 2.

---

**Algoritmo 2** Algoritmo de la Función *better*

---

```
si al eliminar el contorno  $b_i$  no causa la unión de otros contornos entonces
    devolver VERDAD
fin si
si  $b_i$  no es mucho más corto que los contornos que se van a unir entonces
    devolver VERDAD
fin si
si al menos dos de los contornos que se van a unir tienen valores muy distintos
de  $fm()$  entonces
    devolver FALSO
fin si
```

---

El uso de esta función se puede entender más fácilmente viendo el ejemplo representado en la figura 4.24. En esta situación resultará imposible eliminar los dos contornos débiles ( $KC$  y  $KB$ ), es decir, contornos con valores bajos de  $fm()$ , ya que esto implicaría que el borde  $AK$  no sería una frontera entre dos regiones diferentes. Como la longitud del borde  $BK$  es pequeña, el cálculo de su función de mérito no es muy fiable, y si lo eliminamos, entonces tendríamos que unir el borde  $AK$  con el borde  $KC$ . Pero como estos dos contornos tienen una longitud considerable y funciones de mérito muy diferentes, se produce una situación conflictiva. Si decidimos ignorar el resultado del cálculo del borde  $BK$  y más tarde se decide eliminar el borde  $CK$ , entonces se unirían el borde  $AK$  con  $BK$  y tendríamos el borde  $AKB$  como parte de un contorno entre dos regiones. En esta situación la función *better()* no permitirá eliminar el borde  $BK$  pero sí el  $CK$ .

Así pues, el proceso de eliminación de contornos está controlado por tres parámetros, que son: el umbral de contraste entre dos regiones  $\theta$ , el porcentaje de similitud de dos funciones de mérito, y la relación mínima entre longitudes de dos contornos.

Concluida la etapa de eliminación de contornos, obtenemos una imagen en la que se han reducido considerablemente el número de contornos. La zona correspondiente al cordón de soldadura puede todavía incluir a varias regiones, de ahí que se precise de una etapa de alto nivel donde se trate de reconocer, de entre todas las regiones generadas, el cordón de soldadura.

### Bloque de alto nivel

La última fase, o bloque de alto nivel, tendrá como entradas la imagen original y la imagen de regiones elementales de la fase intermedia. Como salida producirá una imagen con el cordón totalmente aislado. El esquema básico de las etapas que constituyen este bloque se muestra en la figura 4.25.

Las regiones obtenidas tras el bloque de procesamiento intermedio constituyen una primera descripción de la imagen. El objetivo ahora es proporcionarles significado. Para ello, las regiones se caracterizan mediante un conjunto de propiedades morfológicas, posicionales y relacionales. Estas propiedades son: el área (*area*), valor medio de nivel de gris (*vmg*), coordenadas del centro de masas (*cmx*, *cmx*) y valores

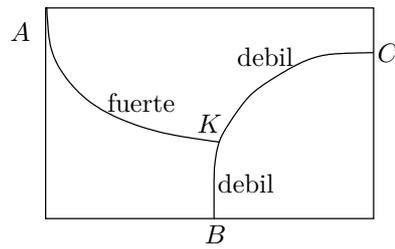


Figura 4.24: Ejemplo de funcionamiento de la función *better*.

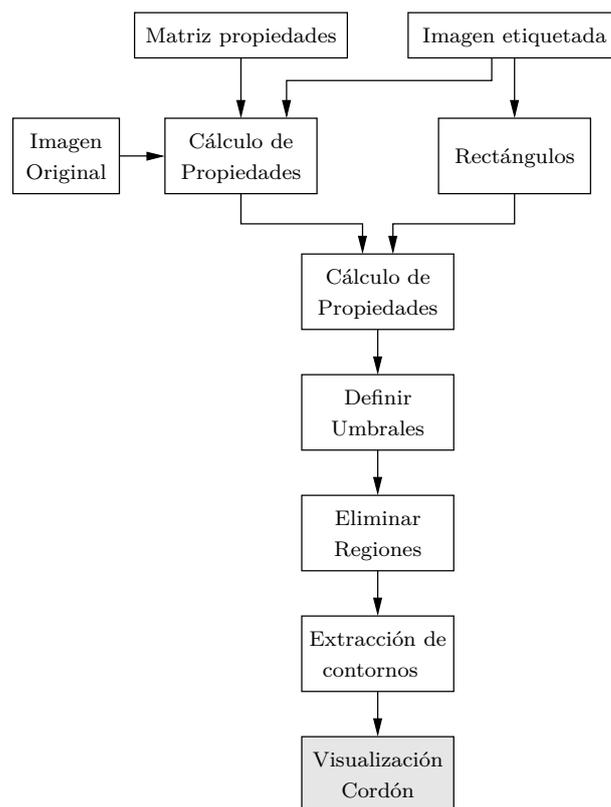


Figura 4.25: Esquema del bloque alto nivel para la segmentación progresiva.

máximos ( $xmax$ ,  $ymax$ ) y mínimos ( $xmin$ ,  $ymin$ ) en dos direcciones. Si denominamos  $g(i, j)$  al valor del nivel de gris en el punto  $(i, j)$ , las propiedades para una región  $k$  se calculan según las siguientes expresiones:

$$\begin{aligned}
 area_k &= \sum_{(i,j) \in k} & vmg_k &= \frac{\sum_{(i,j) \in k} g(i, j)}{area_k} \\
 cmx_k &= \frac{\sum_{(i,j) \in k} i}{area_k} & cmy_k &= \frac{\sum_{(i,j) \in k} j}{area_k} \\
 xmax_k &= \max_{(i,j) \in k} \{i\} & xmin_k &= \min_{(i,j) \in k} \{i\} \\
 ymax_k &= \max_{(i,j) \in k} \{j\} & ymin_k &= \min_{(i,j) \in k} \{j\}
 \end{aligned} \tag{4.11}$$

Con estas propiedades calculadas para cada región elemental, construimos una estructura de datos con la que trabajaremos para realizar la unión de regiones y, a partir de ella, calcular los nuevos valores de propiedades de las nuevas regiones. Así, la actualización de dichas propiedades cuando se unen dos regiones,  $k_1$  y  $k_2$ , para formar una región  $k$ , vendrán dadas por las ecuaciones:

$$\begin{aligned}
 area_k &= area_{k1} + area_{k2} \\
 vmg_k &= \frac{vmg_{k1} \cdot area_{k1} + vmg_{k2} \cdot area_{k2}}{area_k} \\
 cmx_k &= \frac{cmx_{k1} \cdot area_{k1} + cmx_{k2} \cdot area_{k2}}{area_k} \\
 cmy_k &= \frac{cmy_{k1} \cdot area_{k1} + cmy_{k2} \cdot area_{k2}}{area_k} \\
 xmax_k &= \max\{xmax_{k1}, xmax_{k2}\} \\
 xmin_k &= \min\{xmin_{k1}, xmin_{k2}\} \\
 ymax_k &= \max\{ymax_{k1}, ymax_{k2}\} \\
 ymin_k &= \min\{ymin_{k1}, ymin_{k2}\}
 \end{aligned} \tag{4.12}$$

De forma paralela al cálculo de propiedades, y con el fin de situar espacialmente a cada región, se calcula para cada una de las regiones el mínimo rectángulo que las encierra *bounding box*, lo que permitirá determinar la máxima coordenada  $(x, y)$  que alcanza cada región, y establecer si dos o más regiones interseccionan entre sí.

A continuación, definimos un conjunto de umbrales; de nivel de gris medio, de tamaño y de posición espacial para la identificación correcta de los cordones de soldadura. Para fijar estos umbrales, nos basamos en el análisis de resultados obtenidos tras la aplicación del algoritmo de segmentación progresiva sobre una colección de alrededor de 50 radiografías. De esta forma, para el nivel de gris se fijaron un umbral mínimo ( $u_{min}$ ) de 110 y un máximo ( $u_{max}$ ) de 190. En cuanto a los umbrales de posición únicamente se fijó el de posición horizontal  $x$ , ya que la posición vertical del cordón de soldadura puede variar considerablemente dependiendo de cómo se hubiese realizado la radiografía, de forma que el cordón puede quedar muchas veces descentrado verticalmente.

El umbral de posición en dirección horizontal es fácilmente determinable, pues el cordón de soldadura ocupa todo el ancho de la radiografía. Un criterio muy riguroso sería establecer como umbral mínimo la coordenada cero y como el máximo 639; sin embargo, introducimos un cierto grado de tolerancia aumentando el umbral mínimo a 50 y reduciendo el máximo a 580.

Para determinar las coordenadas en el eje horizontal de inicio ( $x_{inic}$ ) y finalización ( $x_{fin}$ ) de cada una de las regiones, se calcula el menor rectángulo que contiene a cada una de las regiones, lo que permite determinar fácilmente las anteriores coordenadas.

Una vez calculados los umbrales de gris y posición, intentaremos identificar el cordón de soldadura entre las regiones más grandes de la imagen, que generalmente resulta ser la segunda más grande tras la región que forma el fondo de la radiografía. De acuerdo con esto, umbral de tamaño ( $u_{tam}$ ) se fija en 12000 píxeles, que resulta ser aproximadamente un 4% del área total de la imagen.

De esta forma, las reglas de producción para identificar el cordón de soldadura son muy sencillas, pues simplemente buscamos las zonas claras centradas verticalmente que ocupen gran parte de la dimensión horizontal de la imagen y que se encuentren entre las de mayor tamaño. Por tanto, el posible cordón de soldadura debe cumplir los siguientes criterios:

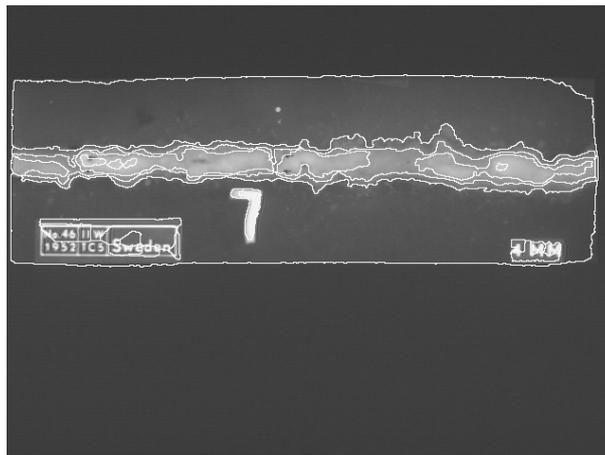
1. Criterio nivel de gris:  $u_{min} < vmg_i < u_{max}$
2. Criterio de posición:  $x_{inic} < x_1$  y  $x_2 < x_{fin}$
3. Criterio de tamaño:  $u_{tam} < area_i$

siendo  $vmg$  el valor medio nivel de gris,  $x_1$  la coordenada origen de la región,  $x_2$  la coordenada finalización de la región y  $area_i$  el tamaño en número de píxeles.

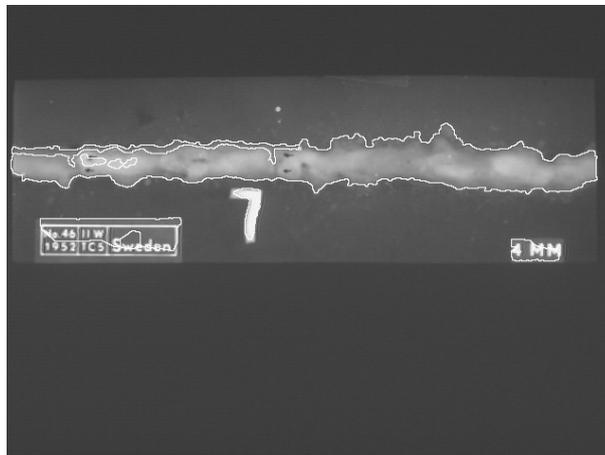
Para finalizar el bloque de alto nivel, aplicamos el algoritmo de extracción de contornos, análogo al desarrollado en el bloque de bajo nivel, lo que permite visualizar la región identificada como cordón de soldadura en la forma de una imagen de contornos. En la figura 4.26 se muestran las imágenes resultado de cada uno de los bloques de procesamiento y en donde como resultado final queda delimitado de forma muy precisa el cordón de soldadura.

### 4.3.3 Técnica de Segmentación Basada en Etiquetado de Componentes Conectados

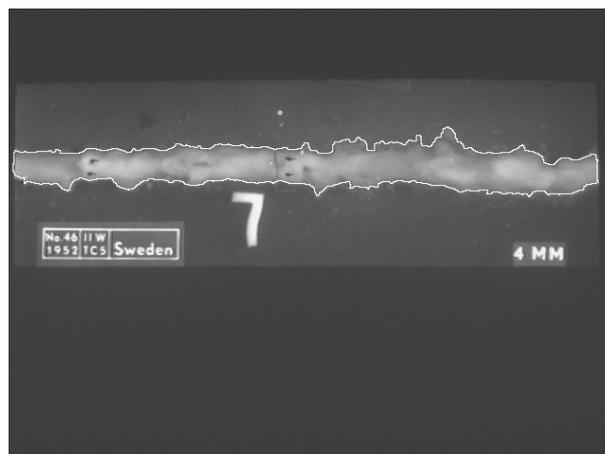
Nuestra última propuesta para conseguir aislar el cordón de soldadura de la imagen radiográfica [101], se desarrolla en tres fases, siguiendo el esquema de la figura 4.27. En la primera fase se procede a la búsqueda y selección del umbral óptimo para realizar la segmentación de la imagen, en una segunda fase se se procede al etiquetado de las regiones obtenidas en la fase anterior para finalmente en una tercera fase, una vez calculadas las áreas de las regiones, establecer un criterio de selección que nos permita identificar de entre todas la que coincide con el cordón de soldadura.



(a)



(b)



(c)

Figura 4.26: Imágenes resultado de: (a) bloque de bajo nivel, (b) bloque de nivel intermedio, (c) bloque de alto nivel.

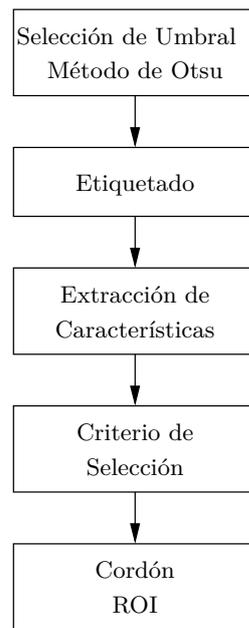


Figura 4.27: Esquema general de segmentación basada en el etiquetado de componentes conectados.

### Selección del Umbral.

El objetivo de la primera fase es encontrar un umbral global óptimo que pueda utilizarse para convertir la imagen de niveles de gris a una imagen binaria, separando los píxeles de interés de los del fondo. La umbralización es una técnica de segmentación ampliamente utilizada en las aplicaciones industriales. Se emplea cuando hay una clara diferencia entre los objetos a extraer respecto del fondo de la escena, y se basa en la similitud entre los píxeles pertenecientes a un objeto y sus diferencias respecto al resto. Por tanto, la escena debe caracterizarse por un fondo uniforme y por objetos parecidos.

Al aplicar un umbral, la imagen de niveles de grises quedará binarizada, etiquetando con 1 los píxeles correspondientes al objeto y con 0 aquellos que son del fondo. Por ejemplo, si los objetos son claros respecto del fondo, se aplicará:

$$g(x, y) = \begin{cases} 1 & f(x, y) > T \\ 0 & f(x, y) \leq T \end{cases} \quad (4.13)$$

donde  $f(x, y)$  es la función que retorna el nivel de gris del píxel  $(x, y)$ ,  $g(x, y)$  será la función de la imagen binarizada y  $T$  es el umbral. En el caso de que los objetos sean oscuros respecto del fondo, la asignación sería a la inversa:

$$g(x, y) = \begin{cases} 1 & f(x, y) < T \\ 0 & f(x, y) \geq T \end{cases} \quad (4.14)$$

El umbral puede depender de  $f(x, y)$ , de alguna propiedad local del píxel,  $p(x, y)$  y hasta de su propia posición:

$$T = T(f(x, y), p(x, y), x, y) \quad (4.15)$$

Si el umbral sólo depende de  $f(x, y)$  se dice que es un umbral global; en el caso de que además dependa de alguna propiedad  $p(x, y)$ , por ejemplo, el valor medio del entorno de vecindad, el umbral se denomina local; si depende también de la posición del píxel, se denominará dinámico. En cualquier caso, el problema es encontrar el umbral adecuado, tarea nada sencilla ya que las imágenes están contaminadas con ruido.

La segmentación por histograma es una técnica global que se basa en considerar una definición clara de los objetos respecto del fondo, con una iluminación relativamente uniforme en toda la escena, lo que lleva a suponer que el histograma está constituido por dos picos y un valle, definiéndose el umbral justamente en dicho valle. Segmentar empleando el histograma supone no considerar las relaciones de vecindad de los píxeles.

Esta técnica es extensible a un histograma con  $N$  picos y  $N-1$  valles, presentado varios umbrales. Sin embargo, a mayor número de umbrales en la imagen, menos fiables serán los resultados.

La umbralización por histograma presenta ciertas limitaciones: es difícil identificar correctamente los mínimos del histograma, se tienen problemas cuando las regiones varían suavemente su nivel (por ejemplo, el efecto de las sombras), se aplica sólo cuando hay pocas regiones, no se pueden distinguir regiones separadas de niveles similares de gris y no considera la conectividad de los píxeles. Debido a estos inconvenientes, se suelen emplear técnicas de post-procesado tras la umbralización.

Hay diferentes estrategias para la elección del umbral óptimo. Entre ellas destacan aquéllas cuyos fundamentos se basan en: el ajuste gaussiano, la minimización de la varianza interclase, la entropía del histograma, el análisis de la concavidad y los métodos basados en momentos. Un resumen detallado de los distintos algoritmos se puede encontrar la revisión realizada por Sahoo [86]. De entre todas las propuestas cabe destacar el umbral de Otsu [81], por su alta utilización en las aplicaciones de Visión Artificial. Ha sido precisamente este método el que hemos utilizado en esta primera fase para la selección del umbral a partir de los histogramas de niveles de grises.

Este método se basa en la suposición de que la función de densidad del fondo,  $C_f$ , y de los objetos,  $C_0$ , tienen modelo gaussiano,  $N(\mu_f, \sigma_f^2)$  y  $N(\mu_0, \sigma_0^2)$ , respectivamente. Cada grupo estará formado por los niveles de grises delimitados por el umbral  $T$ :

$$C_f = \{0, 1, 2, \dots, T\} \quad C_0 = \{T + 1, T + 2, \dots, I - 1\} \quad (4.16)$$

El umbral debe de minimizar la suma ponderada de las varianzas de las clases,  $C_f$  y  $C_0$ , ya que se supone que conforme la suma de las dos clases se aproxime más al histograma real, las desviaciones serán menores.

Para determinar los coeficientes se toman las probabilidades de cada una de las clases. Considerando un valor fijo de umbral,  $T$ , las probabilidades de cada categoría serán:

$$P_{C_f} = \sum_{i=0}^T p_i \quad P_{C_0} = \sum_{i=T+1}^{I-1} p_i \quad (4.17)$$

donde  $p_i$  es la probabilidad de la intensidad  $i$  en la imagen. Las medias y varianzas de cada grupo corresponderán a:

$$\begin{aligned}\mu_{C_f} &= \frac{1}{P_{C_f}} \sum_{i=0}^T i \cdot p_i & \mu_{C_0} &= \frac{1}{P_{C_0}} \sum_{i=T+1}^{I-1} i \cdot p_i \\ \sigma_{C_f}^2 &= \frac{1}{P_{C_f}} \sum_{i=0}^T (i - \mu_{C_f})^2 \cdot p_i & \sigma_{C_0}^2 &= \frac{1}{P_{C_0}} \sum_{i=0}^T (i - \mu_{C_0})^2 \cdot p_i\end{aligned}\quad (4.18)$$

siendo entonces la varianza ponderada:

$$\sigma_p^2 = P_{C_f} \cdot \sigma_{C_f} + P_{C_0} \cdot \sigma_{C_0} \quad (4.19)$$

El procedimiento consiste en recorrer todo el rango de niveles de gris (de 0 a  $I - 1$ ), calculándose la varianza ponderada, y se elige el umbral  $T$  que minimiza este valor. Una vez obtenido el valor del umbral, la imagen de niveles de gris puede ser binarizada.

### Etiquetado

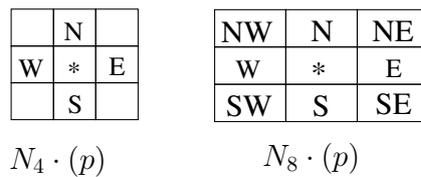
En una segunda fase, se procede al etiquetado de los objetos presentes en la imagen binaria obtenida en la primera fase, en donde los elementos de valor 1 representan los píxeles de primer plano (*foreground*), el resto tienen el valor 0 y representan los píxeles del fondo (*background*). El objetivo ahora es identificar todos los grupos de píxeles que están interconectados con los objetos de la imagen, proceso que se conoce como etiquetado de componentes conectados (CCL).

El etiquetado de componentes conectados de una imagen binarizada,  $BW$ , produce una imagen etiquetada  $L$  en la que el valor de cada píxel es una etiqueta de sus componentes conectados. Existen varios métodos para encontrar componentes conectados de una imagen binaria, y la forma de definir la adyacencia o vecindad de los píxeles afecta a los resultados. Antes de comenzar con el análisis de los algoritmos específicos para realizar el etiquetado de componentes conectados, conviene introducir el concepto de conectividad.

Un píxel  $p$  de coordenadas  $(x, y)$  tiene dos vecinos horizontales y dos vecinos verticales cuyas coordenadas son  $(x + 1, y)$ ,  $(x - 1, y)$ ,  $(x, y + 1)$  y  $(x, y - 1)$ . Este conjunto de píxeles, que con frecuencia se les nombra como sus vecinos norte, sur, este y oeste respectivamente, constituyendo el conjunto de los 4-vecinos de  $p$  que denotaremos por  $N_4.(p)$ . Los cuatro vecinos diagonales de  $p$  con coordenadas  $(x + 1, y + 1)$ ,  $(x + 1, y - 1)$ ,  $(x - 1, y + 1)$  y  $(x - 1, y - 1)$ , constituyen el conjunto  $N_D.(p)$ . La unión de  $N_D.(p)$  y  $N_4.(p)$  constituyen los 8-vecinos de  $p$  ( $N_8.(p)$ ). Dos píxeles  $p$  y  $q$  se dicen que son 4-adyacentes si  $q \in N_4.(p)$ . De manera similar,  $p$  y  $q$  se dicen que son 8-adyacentes si  $q \in N_8.(p)$ . La figura 4.28 ilustra estos conceptos.

Una trayectoria o *path* entre píxeles  $p_1$  y  $p_n$  es una secuencia de píxeles  $p_1, p_2, \dots, p_{n-1}, p_n$  tales que  $p_k$  es adyacente a  $p_{k+1}$ , para  $1 \leq k < n$ . Una trayectoria puede ser 4-conectada o 8-conectada, dependiendo de la definición de adyacencia utilizada.

Dos píxeles de primer plano  $p$  y  $q$  se dicen que están 4-conectados si existe una trayectoria 4-conectada entre ellos constituida exclusivamente por píxeles de primer

Figura 4.28: Vecindad  $N_4(p)$  y  $N_8(p)$ .

plano. De forma similar se diran 8-conectados si existe una trayectoria 8-conectada entre ellos. Para cualquier píxel de primer plano,  $p$ , a todos los píxeles de primer plano conectados que contienen a  $p$  se les llama componentes conectados. El término componente conectado lo hemos definido en términos de una trayectoria, y una trayectoria a su vez depende de una adyacencia. Esto conduce a que la naturaleza de un componente conectado dependa de la forma de adyacencia que elijamos.

De entre los diferentes métodos formulados para realizar el etiquetado de componentes conectados, en este trabajo no hemos decantado por una propuesta que conlleva realizar dos pasadas sobre la imagen: una primera pasada para registrar equivalencias y asignar temporalmente etiquetas, y una segunda para reemplazar cada etiqueta temporal por la etiqueta de su clase de equivalencia. Entre las dos pasadas se realiza un paso intermedio llamado *determinación de clases equivalentes (equivalence class resolution)*, siguiendo la idea de Haralick y Shapiro [37], mediante el cual el conjunto de equivalencias registrado y almacenado como una relación binaria se procesa mediante el algoritmo *union-find*, como se muestra en el algoritmo 1, que determina las clases de equivalencia. Veamos una ilustración del procedimiento, utilizando la imagen binaria ejemplo de la figura 4.29 (BW).

La primera pasada asigna temporalmente etiquetas a cada píxel de primer plano. Comenzamos recorriendo la imagen por columnas, y cuando encontramos un píxel de primer plano o píxel de valor 1, observamos los píxeles vecinos. Para el píxel encontrado en primer lugar (4,2), comprobamos que a ninguno de los vecinos resaltados se le ha asignado todavía una etiqueta temporal, por lo que se le asigna la etiqueta (1) al píxel correspondiente a esa ubicación en la matriz de etiquetas (L), tal como aparece en la figura 4.30 (a). Siguiendo con el escaneo de la imagen, encontramos el segundo píxel de primer plano localizado en la posición (5,2). Comprobamos que uno de los píxeles vecinos tiene ya la etiqueta (1), por lo que a este píxel se le asigna la etiqueta temporal (1) en la matriz de etiquetas (L), tal como se ilustra en la figura 4.30 (b). Cuando en el recorrido de la imagen llegamos al píxel (2,4), comprobamos que ninguno de los píxeles vecinos ya escaneados han sido etiquetados, de modo que a este píxel se le asigna temporalmente una nueva etiqueta (2), tal como refleja la figura 4.30 (c).

Continuamos escaneando y el siguiente píxel que nos encontramos no nulo es el que ocupa la posición (3, 4). Comprobamos que uno de los píxeles vecinos escaneados se le ha asignado la etiqueta (1), pero a otro de los vecinos le fue asignada la etiqueta (2). En estas situaciones, el algoritmo elige arbitrariamente una de las etiquetas y registra el hecho de que temporalmente la etiqueta (1) y la (2) realmente se refieren

---

**Algoritmo 3** Algoritmo de Etiquetado de Componentes Conectados con *Union-Find*

---

**B** imagen binaria original

**LB** imagen de etiquetas de los componentes conectados

**MaxRow** número de la última fila de la imagen

**MaxCol** número de la última columna de la imagen

Inicializar estructuras;

Paso 1 asignar etiquetas iniciales para cada fila  $L$  de la imagen

**para**  $L = 0$  a MaxRow **hacer**

    Inicializar todas las etiquetas en la línea  $L$  a cero

**para**  $P = 0$  a MaxCol **hacer**

$LB[L, P] = 0$

    Procesar línea  $L$

**para**  $P = 0$  a MaxCol **hacer**

**si**  $B[L, P] = 1$  **entonces**

$A =$  anterior vecino  $(L, P)$

**si**  $(A)$  está vacío **entonces**

$M = label; label = label + 1$

**si no**  $\{M = \min(label(A))\}$

$LB[L, P] = M$

**para**  $M$  en  $label(A)$  Y  $X \neq M$  **hacer**

            union  $(M, X, PARENT)$

**fin para**

**fin si**

**fin si**

**fin para**

**fin para**

**fin para**

Paso 2 reemplazar etiquetas del paso 1 con etiquetas de clases de equivalencias

**para**  $L = 0$  a MaxRow **hacer**

**para**  $P = 0$  a MaxCol **hacer**

**si**  $B[L, P] = 1$  **entonces**

$LB[L, P] = \text{find}(LB[L, P], PARENT)$

**fin si**

**fin para**

**fin para**

---

BW							
0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	1	0	1	1	1
0	1	1	1	0	0	0	1
0	1	0	0	0	1	1	1
0	0	0	0	0	0	0	0

Figura 4.29: Imagen binaria ejemplo.

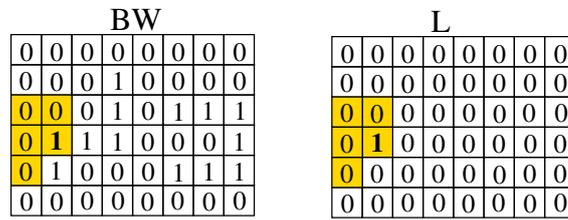
al mismo objeto, tal como ilustra la figura 4.30 (d). Esta situación ocurre de nuevo en el píxel (4, 8), de forma que siguiendo el procedimiento adoptado anteriormente tendremos que temporalmente las etiquetas (3) y (4) se refieren al mismo objeto de la figura 4.30 (e).

De esta manera, los pares de etiquetas (1)-(2) y (3)-(4), constituyen lo que llamamos una equivalencia y forman la tabla de equivalencia. Cuando la primera pasada está terminada obtenemos una matriz de etiquetas temporales (LT) de la imagen binaria ejemplo (BW), que se muestra en la figura 4.31.

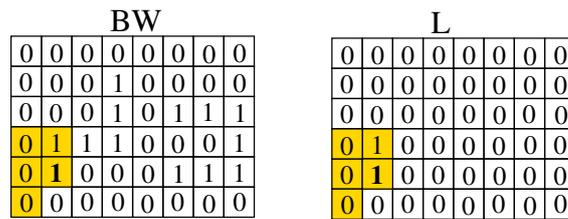
El proceso de determinar qué subconjuntos de etiquetas temporales realmente se refieren al mismo objeto se denomina *equivalence class resolution* y se realiza utilizando el algoritmo *union-find*. La estructura de datos creada por este algoritmo permite construir y manejar de forma sencilla las clases de equivalencia representadas por estructuras de tipo árbol, cuyo propósito es almacenar una serie de conjuntos disjuntos e implementar de manera eficiente las operaciones *union* o fusión de dos conjuntos en uno y *find* o determinación de a qué conjunto pertenece un determinado elemento.

En estas representaciones de cada uno de los conjuntos y los nudos del árbol representan etiquetas que apunta a su único nudo padre. Todo esto se consigue con un sólo vector matriz cuyos subíndices son los conjuntos de etiquetas posibles, y cuyos valores son las etiquetas de los nudos padre. Un valor cero significará que ese nudo es la raíz del árbol. La figura 4.32 ilustra la estructura de árbol de dos conjuntos de etiquetas; (1, 2, 3, 4, 8) y (5, 6, 7). La etiqueta (3) es el nudo padre del primer conjunto de etiquetas y la etiqueta (7) es el nudo padre del segundo conjunto de etiquetas. Los valores en la matriz nos indican que los nudos (3) y (7) no tienen padres, que la etiqueta (2) es el padre de la (1), y que la etiqueta (3) es padre de las etiquetas (2, 4) y (8).

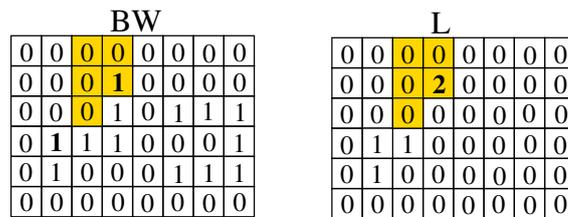
El procedimiento *find* como se expresa en el algoritmo 4, para una etiqueta dada,  $X$ , consiste simplemente en seguir los punteros padres hacia arriba del árbol para encontrar la etiqueta del nudo raíz en el árbol donde se encuentra ( $X$ ). El procedimiento *union* expresado en el algoritmo 5, para dos etiquetas ( $X$ ) y ( $Y$ ) consiste en modificar, si fuera necesario, la estructura para unir el conjunto que contiene ( $X$ ) con el que contiene a ( $Y$ ). Se inicia en las etiquetas ( $X$ ) e ( $Y$ ) y se sigue con los punteros padres hacia arriba del árbol hasta alcanzar las raíces de los dos conjuntos.



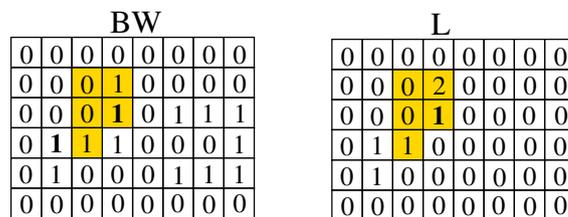
(a)



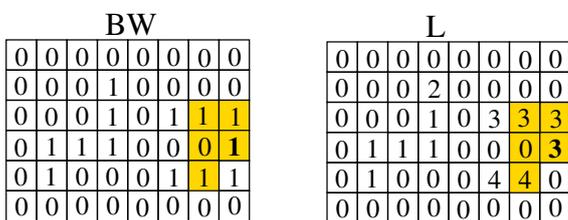
(b)



(c)



(d)

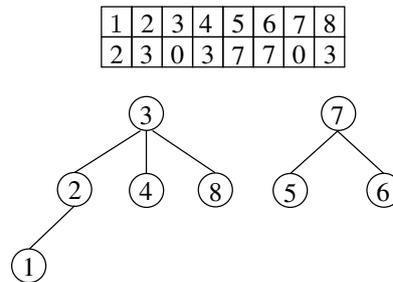


(e)

Figura 4.30: Aplicación del método de etiquetado de componentes conectados

LT							
0	0	0	0	0	0	0	0
0	0	0	2	0	0	0	0
0	0	0	1	0	3	3	3
0	1	1	1	0	0	0	3
0	1	0	0	0	4	4	3
0	0	0	0	0	0	0	0

Figura 4.31: LT: Matriz de Etiquetas Temporales

Figura 4.32: Estructura de datos *union-find*.**Algoritmo 4** Algoritmo *Find***X** etiqueta del conjunto**PARENT** matriz que contiene la estructura *union-find***procedimiento** *find*( $X, PARENT$ ) $j = X$ **mientras**  $PARENT[j] \neq 0$  **hacer** $j = PARENT[j]$ **fin mientras**

La figura 4.33 ilustra la aplicación de este algoritmo a la imagen binaria de la figura 4.29. La parte (a) de la figura 4.33 muestra las etiquetas de cada píxel después de la primera pasada. La parte (c) de esta muestra la estructura de datos *union-find*, indicando que las clases de equivalencia determinadas en la primera pasada son: (1, 2, 3, 4). La parte (d) de la misma figura muestra la estructura de árbol para los dos conjuntos de etiquetas, mientras que en la parte (b) se presenta el etiquetado final de la imagen después de la segunda pasada, y una vez se han seguido las etiquetas de forma ascendente en el árbol, para su unión en las dos categorías resultantes. La etiqueta final (1) representa la unión de las intermedias (1) y (2), mientras que la etiqueta final (2) corresponde a la unión de (3) y (4).

**Identificación del cordón de soldadura**

Para concluir con las etapas del método propuesto para segmentar el cordón de soldadura, en una tercera fase se establece el área máxima como criterio para la selección entre los objetos etiquetados. De esta manera, identificamos el cordón

**Algoritmo 5** Algoritmo *Union*


---

**X** etiqueta del primer conjunto  
**Y** etiqueta del segundo conjunto  
**PARENT** matriz que contiene la estructura *union-find*

**procedimiento** *union*(*X*, *Y*, *PARENT*)  
 $j = X$   
 $k = Y$   
**mientras**  $PARENT[j] \neq 0$  **hacer**  
     $j = PARENT[j]$   
    **mientras**  $PARENT[k] \neq 0$  **hacer**  
         $k = PARENT[k]$   
    **fin mientras**  
**fin mientras**  
**si**  $j \neq k$  **entonces**  
     $PARENT[k] = j$   
**fin si**

---

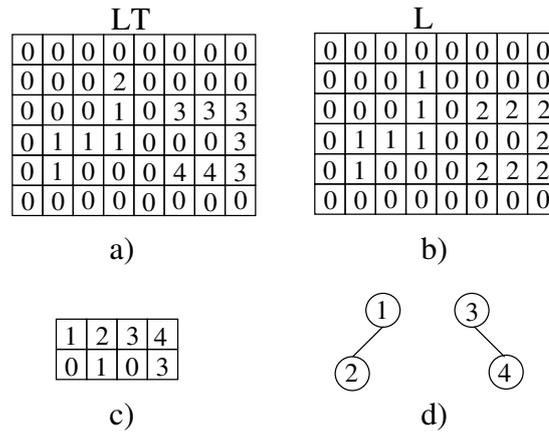


Figura 4.33: Aplicación de algoritmo de etiquetado de componentes conectados con estructura de datos *union-find*.

de soldadura entre todos los objetos de la imagen como aquél que tiene mayor número de píxeles. Para ello, buscamos en la matriz de etiquetas de la imagen obtenida en la etapa anterior el índice (fila y columna), del objeto que cumple con el criterio establecido. Localizado éste, obtenemos la imagen binaria conteniendo el conjunto de píxeles que coinciden con el objeto seleccionado. Finalmente, y para identificar de manera más precisa el cordón de soldadura, calculamos la imagen binaria conteniendo sólo los píxeles del perímetro del objeto, identificando como píxel de perímetro a aquel no nulo que esté 8-conectado por lo menos a un píxel de valor cero.

Los resultados de aplicación de este algoritmo en una imagen ejemplo se muestra en la figura 4.34. Finalmente, como preparación para la siguiente etapa, se calcula el menor rectángulo que contenga el cordón de soldadura o *bounding box*.

#### 4.4 Segmentación de Heterogeneidades Candidatas a Defectos

Una vez aislada la zona de interés, que para nuestro sistema la constituye el cordón de soldadura, debemos abordar quizás la etapa más crítica del proceso ya que de su fiabilidad van a depender en gran parte las prestaciones del sistema en su conjunto. En esta etapa hemos de detectar con la mayor precisión posible las heterogeneidades presentes en la unión soldada, es decir los candidatos a defectos.

Debemos insistir en la importancia que tiene en esta etapa conseguir una buena eficiencia en la detección de defectos; ningún defecto debe quedar sin detectar y el número de falsos positivos no debe ser tan grande que llegue a comprometer el rendimiento del sistema desde el punto de vista del tiempo de computación.

Para conseguir este objetivo proponemos un procedimiento análogo al utilizado en la segunda fase de la etapa anterior para la segmentación del cordón de soldadura, y que denominamos segmentación por etiquetado de componentes conectados [101]. Para aplicar este procedimiento se parte del *bounding box* de la imagen obtenida en la etapa anterior, produciendo como salida una imagen que consta sólo de los candidatos a defectos.

El procedimiento se desarrolla en tres fases. En la primera fase, la imagen contenida en el *bounding box* definido en la fase anterior se binariza. Para esta operación, utilizamos el método de Otsu [81], de cara a obtener el umbral óptimo. Es un procedimiento que para las características de las imágenes que tratamos resulta bastante eficaz, como ya quedó demostrado en la etapa anterior donde también fue utilizado.

Una vez binarizada la imagen de entrada debemos, en una segunda fase, etiquetar los objetos presentes. Para esa tarea utilizamos el procedimiento general propuesto por Haralick and Shapiro [37] para el etiquetado de componentes conectados en la imagen binaria, donde los píxeles etiquetados con 0 constituyen el fondo y los píxeles con etiquetas distintas de cero se corresponden con un objeto. Etiquetada la imagen, seguidamente se procede a aplicar un algoritmo que localiza el borde exterior de los objetos presentes en la imagen, así como los bordes de los huecos situados dentro de estos objetos. Este procedimiento permite determinar el anidamiento de objetos, discriminando objetos completamente encerrados en otros (hijos y padres en nuestra terminología). La figura 4.35 ilustra estos componentes en una imagen sintética.

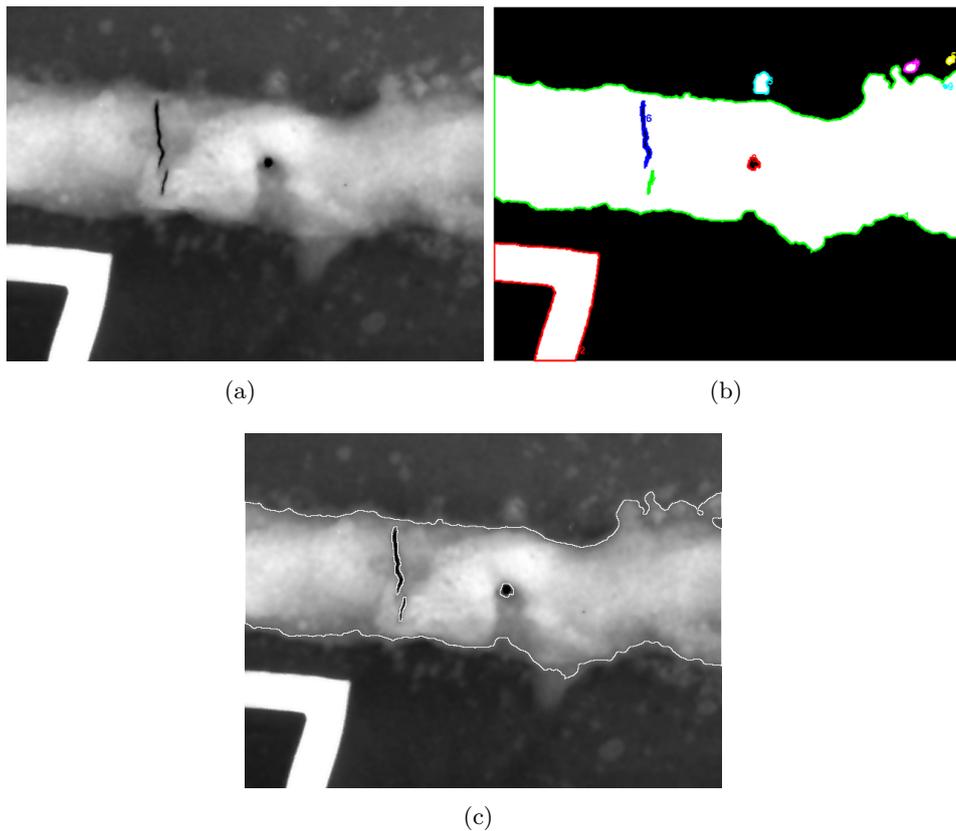


Figura 4.34: Segmentación del cordón de soldadura por etiquetado de componentes conectados: (a) imagen radiográfica; (b) imagen etiquetada; (c) cordón segmentado.

El algoritmo devuelve, en primer lugar, un conjunto de  $P$  matrices, donde  $P$  es el número total de objetos. Se trata de matrices que contienen las coordenadas de los píxeles de borde de cada una de las regiones, por lo que tendrán dos columnas y  $Q_i$  filas, siendo  $Q_i$  el número de píxeles de borde del objeto  $i$ . Al vector cuyas componentes son cada una de estas matrices lo denominaremos **ob**. El algoritmo también devuelve el número de objetos padres e hijos encontrados ( $N$ ), y una matriz de adyacencias (**A**) que representa las relaciones padre-hijo-hueco a través de la posición de las etiquetas de los objetos en las filas de dicha matriz.

Para comprender de manera más clara el proceso seguido por el algoritmo, lo aplicaremos a las imágenes sintéticas mostradas en la figura 4.35. Los resultados de la aplicación de este algoritmo sobre estas imágenes se muestran en la figura 4.36.

Analizando los resultados obtenidos, podemos observar que el vector **ob** contiene seis componentes, correspondientes a cada uno de los contornos de los objetos identificados en la imagen (padres, hijos y huecos). El número de objetos encontrados es  $N = 4$ , que corresponden a tres padres (etiquetados como 1, 3 y 4) y un único hijo (etiquetado como 2), siendo dos los huecos (5 y 6). Las relaciones de dependencia entre padres, hijos y huecos las obtenemos en la matriz de adyacencias (**A**), en la que cada fila contiene las etiquetas de cada pareja de elementos relacionados (5-1,

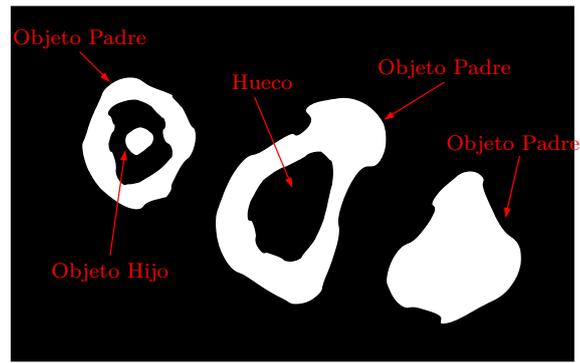


Figura 4.35: Imagen sintética mostrando los bordes de los huecos en el interior de los objetos padres, y los objetos hijos.

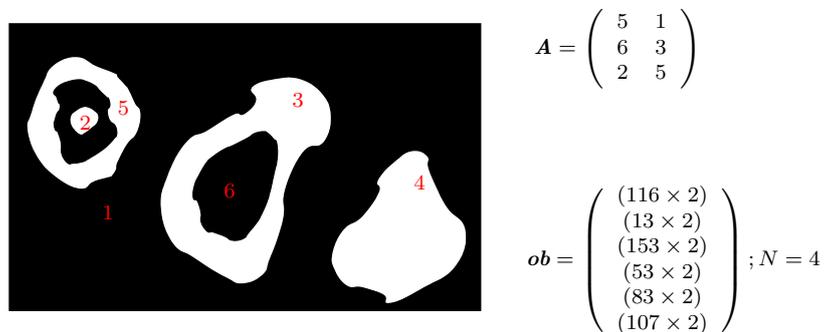


Figura 4.36: Resultados y salida de la aplicación del algoritmo en la imagen sintética.

6-3 y 2-5).

Aplicando el algoritmo descrito sobre el *bounding box* de la imagen del cordón de soldadura delimitado en la etapa previa, podemos obtener la matriz de adyacencias y el vector de contornos (**ob**). Resultan ocho regiones etiquetadas que se ilustran en la figura 4.37, en donde la matriz de adyacencias tiene la siguiente composición:

$$A = \begin{pmatrix} 5 & 1 \\ 6 & 1 \\ 7 & 1 \\ 8 & 1 \end{pmatrix} \quad (4.20)$$

De los ocho objetos segmentados en la imagen, cuatro se han etiquetado como objetos padres (1, 2, 3 y 4) y otros cuatro como huecos (5, 6, 7 y 8). Las relaciones explícitas en la matriz de adyacencias indican que los objetos hueco están incluidos en el objeto padre con etiqueta 1. Como los candidatos a defectos sólo serán los objetos incluidos en el cordón de soldadura (objeto 1), para la siguiente fase sólo se considerarán los que manifiesten esta relación de inclusión.

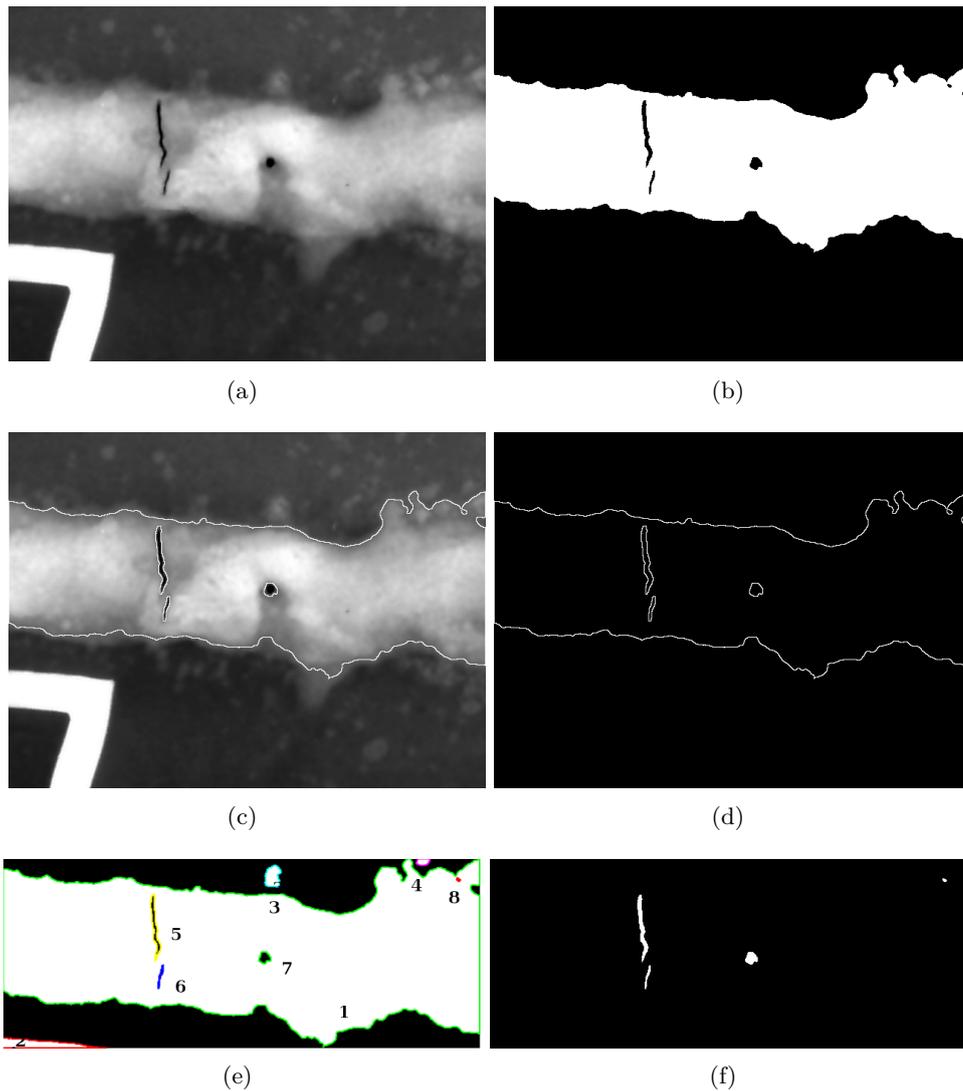


Figura 4.37: Resultado de la aplicación del algoritmo de identificación de heterogeneidades sobre la imagen ejemplo: a) Imagen original; b) Cordón de soldadura segmentado; c) Borde del cordón de soldadura superpuesto en la imagen original; d) Objetos etiquetados incluidos en objeto 1 u objeto cordón; e) Objetos incluidos en el cordón de soldadura candidatos a defectos.

## 4.5 Extracción de Características

La siguiente etapa en un sistema de inspección automática de soldaduras tiene como objetivo la extracción de características individuales y globales de las heterogeneidades detectadas. La selección adecuada de las características supone una reducción considerable de información respecto a la imagen original y tiene una importancia fundamental para asegurar la eficiencia de las siguientes etapas de clasificación del tipo de defecto y catalogación del grado de aceptación. En general se busca el conjunto mínimo de características que permitan determinar de manera unívoca a qué

clase pertenecen los objetos etiquetados en la etapa previa.

Se pueden establecer cinco propiedades que deben exigirse a las características que se seleccionen: economía, velocidad, fiabilidad, capacidad discriminante e independencia con respecto a otras características.

- Economía: El mecanismo preciso para el cálculo o la obtención de las características discriminantes debe tener un coste razonable.
- Velocidad: El tiempo de cálculo no debe superar un límite máximo que en la práctica lo haga inviable.
- Fiabilidad: La fiabilidad comporta que objetos de la misma clase deben tener vectores de características con valores numéricos similares. Esto se cumple si los vectores de características de una clase tienen poca dispersión. La dispersión se puede medir sobre la diagonal de la matriz de covarianzas; cuanto mayores son los valores de la diagonal, mayor es la dispersión.
- Capacidad discriminante: La capacidad discriminante de una característica determinada se puede describir como una propiedad que asegura que patrones de clases distintas tienen valores numéricos claramente diferenciados.
- Independencia: Las características no deben estar correlacionadas entre ellas. Una característica que dependa fuertemente del resto no añade información discriminante y por tanto puede eliminarse sin que esto suponga ninguna pérdida de capacidad de discriminación.

En relación con la propiedad exigible de independencia entre características, existe una medida, la covarianza ( $c_{X,Y}$ ), que permite medir la dependencia lineal entre dos variables aleatorias  $X$  e  $Y$ . La estimación de la covarianza entre dos variables  $X$  e  $Y$  de las que hay  $P$  ocurrencias responde a la siguiente fórmula:

$$c_{X,Y} = \sum_{p=0}^P (X_p - m_X)(Y_p - m_Y) \quad (4.21)$$

siendo  $m_X$  y  $m_Y$  las medias correspondientes a los valores de las variables  $X$  e  $Y$ .

La matriz de covarianzas de las características permite medir la independencia lineal de cada par de ellas dentro de una clase. Para ello, si se dispone de  $N$  características, se construye una matriz de  $N \times N$  para cada clase, de manera que cada elemento de la matriz se corresponde con la varianza de un par de características para esa clase. Debe notarse que es necesario disponer de un número significativo de muestras para construir cada una de las matrices, pues en otro caso los resultados no tendrían ninguna validez. Así, por ejemplo, para la clase  $\alpha_k$  se calcula la matriz  $C_k$  usando las  $P_k$  muestras de aprendizaje para esa clase. En ella cada coeficiente  $c_{ij}$  corresponde a la covarianza entre la característica  $i$  y la  $j$  para las muestras de la clase  $k$ :

$$C_k = \begin{pmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,N} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,N} \\ \vdots & \vdots & \ddots & \vdots \\ c_{N,1} & c_{N,2} & \cdots & c_{N,N} \end{pmatrix} \quad (4.22)$$

que se desarrolla como:

$$C_k = \frac{1}{P_k} \sum_{p=1}^{P_k} \begin{pmatrix} (X_{p1} - m_{k1})(X_{p1} - m_{k1}) & \cdots & (X_{p1} - m_{k1})(X_{pN} - m_{kN}) \\ (X_{p2} - m_{k2})(X_{p1} - m_{k1}) & \cdots & (X_{p2} - m_{k2})(X_{pN} - m_{kN}) \\ \vdots & \ddots & \vdots \\ (X_{pN} - m_{kN})(X_{p1} - m_{k1}) & \cdots & (X_{pN} - m_{kN})(X_{pN} - m_{kN}) \end{pmatrix} \quad (4.23)$$

siendo  $m_{kn}$  el vector media de la característica  $n$  sobre los  $P_k$  muestras de la clase  $k$ .

El elemento  $c_{ij}$  mide la dependencia lineal entre las características  $i$  y  $j$ . Es usual que en lugar de este  $c_{ij}$  se utiliza un valor normalizado de la covarianza  $r_{ij}$  definido de la siguiente manera:

$$r_{ij} = \frac{c_{ij}}{\sqrt{c_{ii}} \cdots \sqrt{c_{jj}}} \quad \forall i, j = 1, 2 \cdots N \quad (4.24)$$

que es independiente de la escala y que se conoce como coeficiente de correlación. Este parámetro toma valores entre  $-1$  y  $1$  y se cumple que si las características  $i$  y  $j$  son linealmente independientes, entonces el valor de  $r_{ij}$  debe estar próximo a cero. Por otro lado, valores cercanos a  $-1$  ó a  $1$  para  $r_{ij}$  indican la existencia de fuertes relaciones lineales entre las características  $i$  y  $j$ .

Cuando una característica es linealmente correlativa con alguna otra, y esto ocurre para todas las clases, puede decidirse eliminarla, ya que ello indica que tal característica no aporta información relevante para el reconocimiento.

De entre los trabajos en el campo del análisis de imágenes radiográficas de uniones soldadas que fueron objeto de revisión en el capítulo 2 de esta memoria, pueden identificarse un conjunto representativo de características geométricas para definir la forma de los defectos, bastante repetidas en muchos de estos trabajos.

La figura 4.38 muestra el resultado de este estudio, las características que hemos seleccionado para definir la forma del defecto son:

1. *Aspecto* ( $a = L/e$ ). Relación entre la longitud del eje mayor y el eje menor de la elipse que se aproxima al contorno de la región. Valores grandes de este parámetro caracterizan defectos longitudinales mientras que valores próximos a 1 representan defectos esféricos.
2. *Relación entre ancho y área* ( $e/A$ ). Mide la relación entre la longitud del eje menor y el área de la citada elipse.
3. *Relación entre longitud y área* ( $L/A$ ). Mide la relación entre la longitud del eje mayor y el área de la elipse.
4. *Índice de extensión* ( $I = \pi L^2/4A$ ). Relación entre la longitud del eje mayor y el área de la elipse. Valores grandes de esta característica indican defectos finos y rectilíneos.
5. *Redondez* ( $Ff = p^2/4\pi A$ ). Se determina mediante la relación entre el perímetro y el área de la región. Valores pequeños de este parámetro indican defectos de formas esféricas.

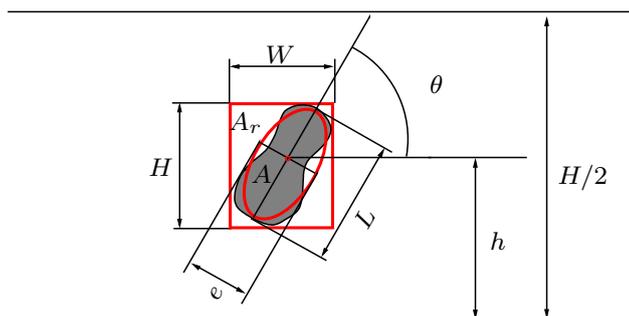


Figura 4.38: Definición de características. La región la forma los píxeles grises; el rectángulo rojo es el bounding box, y el punto rojo es el centroide. La figura muestra una región y su correspondiente elipse con algunas características; ejes y orientación.

6. *Elongación* ( $Elong = W/H$ ). Relación entre la base y la altura del *bounding box*. Valores grandes de este parámetro caracterizan defectos longitudinales (grietas, falta de fusión, falta de penetración, mordeduras, etc.), mientras que valores próximos a 1 representan defectos esféricos.
7. *Rectangularidad* ( $Rect = A/A_r$ ). Representa la proporción de los píxeles del *bounding box* que son también de la región. Su valor está incluido en el intervalo  $[0,1]$ . Si es igual a 1 la forma del defecto es un rectángulo.
8. *Diámetro Equivalente* ( $D = \sqrt{4A/\pi}$ ). Corresponde al diámetro de un círculo con la misma área que la región.
9. *Orientación* ( $\theta$ ). Ángulo entre el eje  $x$  y el eje mayor de la elipse que tiene el mismo momento de segundo orden de la región.

La elección de una combinación de características que proporcionen la mayor eficiencia para clasificar los defectos de soldaduras, y la forma de evaluar la capacidad de cada característica para discriminar los diferentes tipos de defectos, se pueden acometer mediante diversos procedimientos. Para esta tarea realizamos una doble propuesta. La primera sigue la idea planteada por Nacereddine, Hamami y Ziou en las referencias [73] y [74] en donde se propone abordar la clasificación de los defectos de acuerdo a sus características morfológicas. La segunda propuesta consiste en la utilización de la técnica de análisis de componentes principales (PCA) para conseguir simultáneamente una reducción en el número de características y la eliminación de información redundante.

#### 4.5.1 Selección de Características por Categorías Morfológicas

Del examen de un conjunto amplio de radiografías de uniones soldadas conteniendo defectos, y a partir de las características morfológicas obtenidas de los mismos, Nacereddine y colaboradores [73] y [74] establecen cuatro categorías o tipos de formas de defectos. En la primera categoría se incluyen los defectos en los que la forma es alargada, afilada, puntiaguda y rectilínea, como ocurre en los casos de grietas, mordeduras y falta de fusión. En la segunda categoría se incluyen aquellos en los que

la forma es alargada, alisada, suave y rectangular; a esta categoría corresponden la falta de penetración, los poros alargados y las porosidades. En la tercera categoría están los defectos con forma esférica, es decir, porosidades o inclusiones de Tungsteno. Por último, la cuarta categoría comprende los defectos en los que la forma es irregular, no alargada y no esférica; en esta categoría estarían las inclusiones de escoria.

Con esta idea, y para disponer de una estimación preliminar de la relevancia de las características según los tipos de formas, se han construido las imágenes sintéticas mostradas en la figura 4.39. La primera imagen (alargada, alisada, suave y rectangular), representa el arquetipo correspondiente a los defectos del tipo falta de penetración y poros alargados. La segunda es alargada, afilada, puntiaguda y rectilínea, como ocurre en los casos de grietas, mordeduras y falta de fusión. La tercera imagen sintética presenta una forma esférica, es decir, la forma típica de porosidades e inclusiones de Tungsteno. Por último, la cuarta imagen creada tiene una forma irregular, no alargada y no esférica, como corresponde a los defectos debidos a las inclusiones de escoria.

Para cada una de estas imágenes sintéticas se han calculado los valores de las características primarias (área, *bounding box*, longitud del eje mayor y menor de la elipse y perímetro), así como los valores de las características geométricas enumeradas en la sección previa. A dichas características hemos añadido otras que se han considerado pueden aportar al conjunto nuevas capacidades discriminantes, como son:

*Excentricidad* (*Ecc*). Mide la excentricidad de la elipse que se aproxima al contorno de la región. Su valor está comprendido entre 0 y 1; cuando *Ecc* toma el valor 0 el defecto es prácticamente un círculo, mientras que si el valor es 1 el defecto es una línea.

*Número de Euler* (*E*). Representa el número de objetos en la región menos el número de agujeros en esos objetos.

*Solidity* (*Solid*). Expresa la proporción de los píxeles en el *convex hull* que están también incluidos en la región.

Los resultados obtenidos en las imágenes sintéticas para cada característica de las que hemos denominado primarias se muestran en la tabla 4.1, y en la tabla 4.2 se presentan los valores de las 12 características geométricas previamente definidas y que constituyen el punto de partida de nuestra propuesta de caracterización.

Del análisis de estos resultados preliminares sobre las imágenes sintéticas obtenemos algunas pistas empíricas acerca del subconjunto de características que pueden resultar más discriminantes para caracterizar geoméricamente los defectos. Así, en relación con la forma de los defectos, las características que evidencian una mayor aportación de información son: *Excentricidad*, *Rectangularidad*, *Redondez*, *Elongación*, *Aspecto*, *Índice de Extensión* y *Orientación*, que son los valores que aparecen subrayados en la tabla 4.2.



Figura 4.39: Imágenes sintéticas representativas de los cuatro tipos generales de formas de defectos.

Características primarias	Defectos			
	Tipo 1	Tipo 2	Tipo 3	Tipo 4
Área (A)	636	110	52	121
Bounding Box	106.6	59.4	8.8	16.16
Eje Mayor (L)	122.39	68.91	8.17	15.86
Eje Menor (e)	6.92	3.15	8.17	13.73
Perímetro (p)	220	146.7	23.31	57.11

Tabla 4.1: Valores de características primarias obtenidos para las imágenes sintéticas.

Características	Defectos			
	Tipo 1	Tipo 2	Tipo 3	Tipo 4
Aspecto (a)	<u>17.66</u>	<u>21.84</u>	<u>1</u>	<u>1.15</u>
$e/A$	0.01	0.028	0.157	0.113
$L/A$	0.192	0.626	0.157	0.1311
Índice de Extensión (I)	<u>18.5</u>	<u>33.9</u>	<u>1.01</u>	<u>1.63</u>
Redondez (Ff)	<u>6.055</u>	<u>15.58</u>	<u>0.831</u>	<u>2.145</u>
Elongación (Elong)	<u>17.66</u>	<u>14.75</u>	<u>1</u>	<u>1</u>
Rectangularidad (Rect)	<u>1</u>	<u>0.466</u>	<u>0.812</u>	<u>0.472</u>
Diámetro Equivalente (D)	28.45	11.83	8.136	12.41
Orientación (Orient)	<u>0</u>	<u>1.42</u>	<u>0</u>	<u>51.41</u>
Excentricidad (Ecc)	<u>0.998</u>	<u>0.999</u>	<u>0</u>	<u>0.499</u>
Número de Euler (E)	1	1	1	1
Solidity (Solid)	1	0.5446	1	0.747

Tabla 4.2: Valores de características obtenidos para las imágenes sintéticas.

Además de estas características representativas de la morfología de los defectos, es necesario incluir información relativa a la posición de los objetos dentro del cordón de soldadura. Esta posición puede cuantificarse por medio del cociente  $h/H$ , valor que describe la distancia del defecto al centro del cordón de soldadura. Con este parámetro es posible separar, por ejemplo, la falta de penetración, frecuentemente localizada en el centro del cordón de soldadura, de las mordeduras, generalmente localizadas en los bordes.

Para comprobar cualitativamente la validez en imágenes reales de las características que hemos seleccionado a partir de las imágenes sintéticas, se han calculado dichas características para regiones segmentadas de radiografías de la colección IIW, que fueron calificadas previamente por expertos como defectos de alguno de los cua-

tro tipos anteriormente indicados. En la figura 4.40 se muestran los defectos identificados sobre los que se ha realizado la estimación de las características. Los valores resultantes para estos defectos se muestran en la tabla 4.3, apreciándose variaciones significativas de los valores de las características según el tipo de defecto.

En suma, y aplicando criterios de selección de características agrupándolas por categorías morfológicas, hemos seleccionado un vector de características de 8 componentes por cada candidato a defecto detectado, en donde cada componente corresponde al valor calculado de cada una de las características identificadas como más discriminantes para la tipificación de los defectos. En la siguiente sección se aplicará un método formal de reducción de dimensionalidad del espacio de características, a fin de confrontar nuestro análisis empírico con una técnica estadística ampliamente aceptada.

#### 4.5.2 Selección de Características mediante Análisis de Componentes Principales (PCA)

La segunda propuesta para realizar la selección de las características más discriminantes de los objetos detectados consiste en la utilización de la bien conocida técnica de análisis de componentes principales (PCA). Este formalismo nos permitirá seleccionar un conjunto óptimo de características, siempre que la muestra de datos sea estadísticamente significativa.

Cuando se recoge la información de una muestra de datos, lo usual es adoptar una estrategia exhaustiva, tomando el mayor número posible de variables. Sin embargo, si tomamos demasiadas variables sobre un conjunto de objetos, tendremos que considerar  $\binom{N}{2}$  posibles coeficientes de correlación, siendo  $N$  el número de variables, lo que eleva el número de estos coeficientes hasta hacer muy difícil el visualizar las relaciones entre las variables.

Otro problema que se presenta es la fuerte correlación que muchas veces se presenta entre las variables; si tomamos demasiadas variables, lo normal es que estén relacionadas o que midan lo mismo bajo distintos puntos de vista. Se hace necesario, pues, reducir el número de variables.

Es importante resaltar el hecho de que el concepto de mayor información se relaciona con el de mayor variabilidad o varianza. Cuanto mayor sea la variabilidad de los datos (varianza) se considera que contienen mayor información, lo que en cierta manera se relaciona con el concepto de entropía.

Un procedimiento efectivo para reducir la dimensión de los vectores de entrada es el análisis de componentes principales (PCA). Esta técnica fue inicialmente desarrollada por Pearson a finales del siglo XIX y posteriormente fue estudiada por Hotelling en los años 30 del siglo XX. Sin embargo, hasta la aparición de los ordenadores no empezó a popularizarse. PCA es una herramienta estándar en el análisis de datos moderno, ya que constituye una técnica no paramétrica sencilla para extraer información relevante de conjuntos de datos.

Para estudiar las relaciones que se presentan entre  $p$  variables correlacionadas (que miden información común), se puede transformar el conjunto original de va-

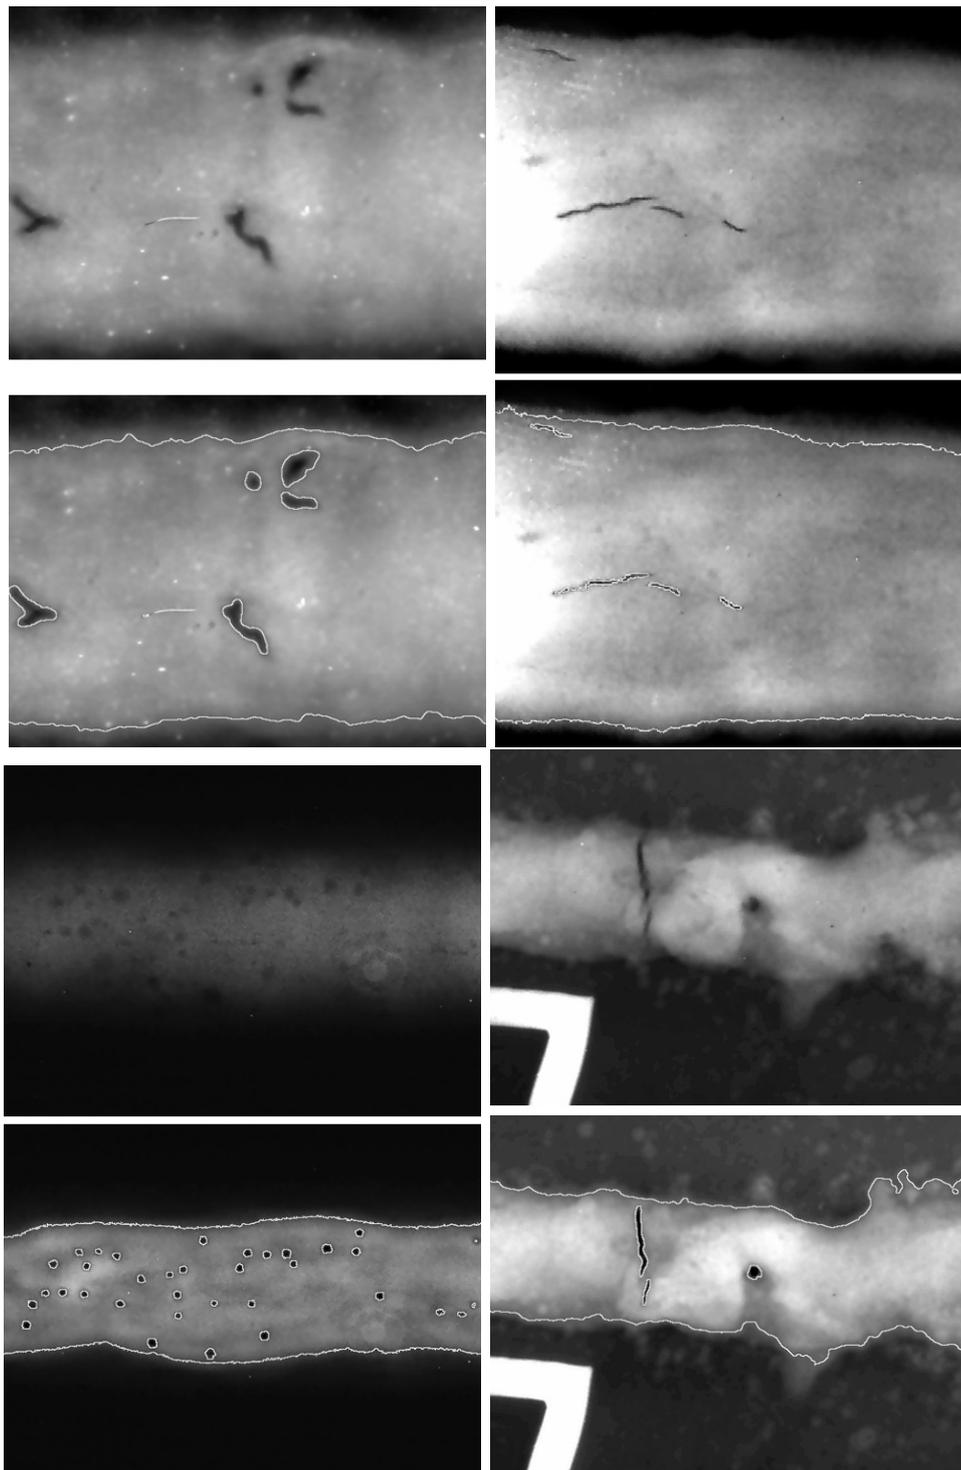


Figura 4.40: Imágenes radiográficas de soldaduras conteniendo defectos. De izquierda a derecha y de arriba a abajo: inclusiones de escoria (radiografía IIW16), grietas longitudinales (radiografía IIW106), poros (radiografía IIW6) y grietas transversales (radiografía IIW46).

Radiografías/ Defectos	Características					
IIW16  Inclusion de Escoria	Ecc.	Orient.	Nº Euler	Diámetro E.	Solid.	Rect.
	0.648	48.28	1.00	32.11	0.80	0.519
	Redondez	Elong.	Aspecto	Índice Ext.	$e/A$	$L/A$
	2.524	0.987	1.287	1.429	0.221	0.323
IIW106  Grieta Longitudinal	Ecc.	Orient.	Nº Euler	Diámetro E.	Solid.	Rect.
	0.993	-16.92	1.00	14.183	0.503	0.37
	Redondez	Elong.	Aspecto	Índice Ext.	$e/A$	$L/A$
	14.25	13.89	22.58	32.85	0.045	0.705
IIW6  Poros	Ecc.	Orient.	Nº Euler	Diámetro E.	Solid.	Rect.
	0.935	-3.57	1.00	7.5694	0.9574	0.803
	Redondez	Elong.	Aspecto	Índice Ext.	$e/A$	$L/A$
	0.789	0.983	0.992	0.984	0.125	0.106
IIW46  Grieta Transversal	Ecc.	Orient.	Nº Euler	Diámetro E.	Solid.	Rect.
	0.993	-69.8	1.00	14.13	0.6515	0.219
	Redondez	Elong.	Aspecto	Índice Ext.	$e/A$	$L/A$
	16.45	14.75	22.48	31.92	0.019	0.562

Tabla 4.3: Valores de características obtenidos para los defectos identificados en las imágenes radiográficas reales.

riables en otro conjunto de nuevas variables no relacionadas entre sí (que no tenga repetición o redundancia en la información) llamado conjunto de componentes principales. Las nuevas variables son combinaciones lineales de las anteriores y se van construyendo según el orden de importancia en cuanto a la variabilidad total que recogen de la muestra. De modo ideal, se buscan  $m < p$  variables que sean combinaciones lineales de las  $p$  originales y que no estén relacionadas, recogiendo la mayor parte de la información o variabilidad de los datos.

Esta técnica tiene tres efectos: ortogonalizar los componentes de los vectores de entrada a fin de que no estén correlacionados unos con otros, ordenar los componentes ortogonales resultantes (componentes principales) de modo que aparezcan primero aquellos con mayor variabilidad, y eliminar aquellos componentes que contribuyen de menor manera a la variabilidad en el conjunto de datos. Su aplicación implica reducir el número de componentes requeridos, tanto como sea posible, sin pérdida de información relevante.

La técnica PCA supone linealidad, de modo que las nuevas bases son una combinación lineal de la original. Esta suposición simplifica realmente el problema, ya que restringe o limita el conjunto posibles de nuevas bases.

Sea  $\mathbf{X}$  el conjunto original de datos, una matriz de dimensión  $m \times n$ , donde  $m$  es el número de medidas y  $n$  el número de ejemplos. Sea  $\mathbf{Y}$  otra matriz de dimensión  $m \times n$  que constituye una nueva representación del conjunto de datos, y que se obtienen de  $\mathbf{X}$  a través de una relación lineal  $\mathbf{P}$ :

$$\mathbf{P}\mathbf{X} = \mathbf{Y} \quad (4.25)$$

La ecuación (4.25) representa un cambio de base, de manera que las filas de  $\mathbf{P}$ ,  $\{\mathbf{p}_1, \dots, \mathbf{p}_m\}$ , suponen la nueva base vectorial en la que se expresarán las medidas de  $\mathbf{X}$ :

$$\begin{aligned} \mathbf{P}\mathbf{X} &= \begin{pmatrix} \mathbf{p}_1 \\ \vdots \\ \mathbf{p}_m \end{pmatrix} \begin{pmatrix} \mathbf{x}_1 & \vdots & \mathbf{x}_n \end{pmatrix} \\ \mathbf{Y} &= \begin{pmatrix} \mathbf{p}_1 \cdot \mathbf{x}_1 & \cdots & \mathbf{p}_1 \cdot \mathbf{x}_n \\ \vdots & \ddots & \vdots \\ \mathbf{p}_m \cdot \mathbf{x}_1 & \cdots & \mathbf{p}_m \cdot \mathbf{x}_n \end{pmatrix} \end{aligned}$$

donde cada columna de  $\mathbf{Y}$  se puede expresar;

$$\mathbf{y}_i = \begin{pmatrix} \mathbf{p}_1 \cdot \mathbf{x}_i \\ \vdots \\ \mathbf{p}_m \cdot \mathbf{x}_i \end{pmatrix}$$

de forma que cada elemento de  $\mathbf{y}_i$  es el producto escalar de  $\mathbf{x}_i$  con la correspondiente fila de  $\mathbf{P}$ . Los vectores fila  $\{\mathbf{p}_1, \dots, \mathbf{p}_m\}$  de esta transformación serán los componentes principales de  $\mathbf{X}$ .

Si cada fila de  $\mathbf{X}$  corresponde a todas las medidas de un tipo particular y cada columna corresponde a un conjunto de medidas de una prueba determinada, definimos ahora la matriz de covarianza  $\mathbf{C}_X$  como:

$$\mathbf{C}_X = \frac{1}{n} \mathbf{X} \mathbf{X}^T$$

Algunas de las propiedades de  $\mathbf{C}_X$  son: los términos de la diagonal son la varianza de un tipo particular de medidas, y el resto de los términos de la matriz representan la covarianza entre tipos de medidas. Si nos referimos a la matriz  $\mathbf{Y}$ , nuestro objetivo es minimizar la redundancia medida por la covarianza y maximizar la señal medida por la varianza. Por lo tanto, para optimizar la matriz de covarianza  $\mathbf{C}_Y$ , todos los términos fuera de la diagonal principal deben ser nulos, es decir,  $\mathbf{C}_Y$  debe ser una matriz diagonal. Dicho de otra forma, los datos del conjunto  $\mathbf{Y}$  no están correlacionados.

El objetivo de PCA es encontrar una matriz ortogonal  $\mathbf{P}$  que relacione el conjunto  $\mathbf{X}$  con una nueva representación  $\mathbf{Y}$ , de modo que la matriz de covarianza  $\mathbf{C}_Y = \frac{1}{n} \mathbf{Y} \mathbf{Y}^T$  sea una matriz diagonal. Las filas de  $\mathbf{P}$  son los componentes principales de  $\mathbf{X}$ .

En la práctica, aplicar la técnica PCA a un conjunto de datos  $\mathbf{X}$  implica restar la media de cada tipo de medida, calcular matriz de covarianza  $\mathbf{C}_X$  y encontrar los autovectores. Una vez encontrados los autovectores los datos pueden ser transformados [80] y [79].

Llevar a cabo una reducción dimensional comporta ignorar algunos autovectores. La elección entre la deseada reducción de dimensión y la no deseada pérdida de información se puede definir como:

$$I_K = \frac{\sum_{i=1}^k \beta_i}{\sum_{i=1}^m \beta_i} \cdot 100 \% \quad (4.26)$$

donde  $k$  denota el número de autovectores utilizados,  $m$  denota la dimensión de los datos de entrada, e  $I_K$  es el porcentaje de información (varianza) que se conserva en la compresión y  $\beta_i$  son los autovalores asociados. El análisis de componentes principales elimina aquellos componentes que contribuyen menos que el porcentaje especificado para la varianza total en el conjunto de datos.

En nuestro trabajo, los datos de entrada al análisis de componentes principales lo forman las 12 características definidas en la sección 4.5.1 de este capítulo. La figura 4.41 muestra la relación entre la pérdida de información en el conjunto de datos o porcentaje de información conservada entre el 80 % y el 99.99 %, y el número de componentes principales, en este caso de 1 hasta 12 características. Hay aparentemente una redundancia significativa en el conjunto de características, porque el análisis de componentes principales reduce el tamaño de los vectores de entrada de una forma drástica, incluso para tasas de pérdidas de información de en torno al 1 %.

Por último, y para concluir con el apartado de extracción de características, indicar que, para el diseño de nuestro sistema, los vectores de características para los dos procedimientos utilizados se generaron sobre un conjunto de imágenes radiográficas conteniendo un número de heterogeneidades catalogadas por los expertos de la siguiente forma: 140 no defectos (falsos positivos), 126 inclusiones de escorias, 87 porosidades, 8 grietas transversales y 14 grietas longitudinales. La distribución de clases defectos utilizada se resume en el gráfico de la figura 4.42.

## 4.6 Clasificación de Defectos

Una vez extraídas las características de los candidatos a defectos y seleccionadas las más relevantes, procede abordar la última etapa de un sistema automático de inspección de imágenes radiográficas de uniones soldadas. En esta última fase, se han de clasificar y catalogar los diferentes candidatos en base a las distintas normas y códigos comúnmente aceptados, como por ejemplo la sección 1 del código ASME [5].

En este trabajo, y para acometer esta tarea, se proponen dos enfoques distintos que se sitúan en campos de gran interés en la actualidad dentro de las técnicas de clasificación de patrones. Por un lado, se propone que el vector de características relevantes obtenido en la etapa anterior, optimizado mediante la técnica de análisis de componentes componentes, sea la entrada de un clasificador no-lineal de patrones utilizando una red neuronal artificial (ANN) [98], [108] y [99]. Y como segunda propuesta, que este vector se aplique a un sistema adaptativo de inferencia neuroborrosa (ANFIS) [109].

A continuación, se exponen de manera detallada cada una de las soluciones propuestas para resolver la etapa de clasificación de defectos.

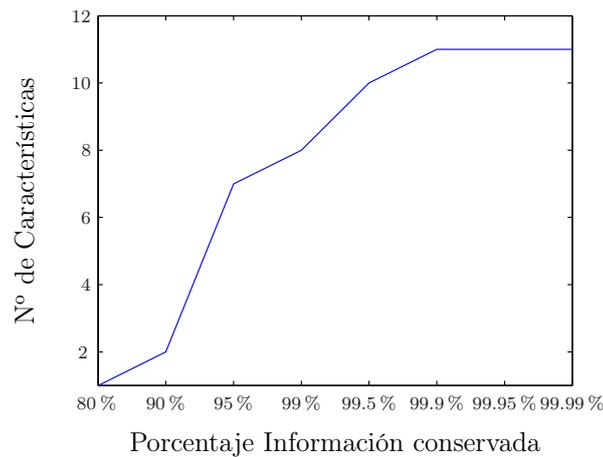


Figura 4.41: Análisis de la contribución de los componentes principales de las características.

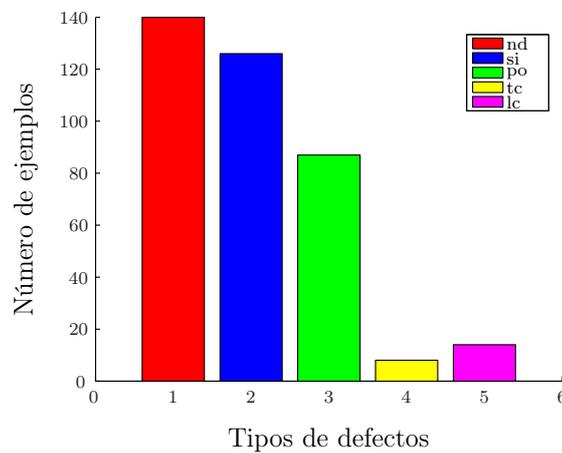


Figura 4.42: Tipos de Defectos: *nd* = no defecto, *si* = inclusión de escoria, *po* = porosidad, *tc* = grieta transversal y *lc* = grieta longitudinal.

#### 4.6.1 Clasificación de Defectos Utilizando una Red Neuronal Artificial Multicapa Retro-alimentada (ANN)

El proceso de creación del clasificador de defectos utilizando una ANN consta en esencia de las siguientes etapas:

1. Obtención de los patrones de entrada/salida.
2. Preparación de los conjuntos de datos para el entrenamiento.
3. Definición de la arquitectura de la red.
4. Entrenamiento de la red.
5. Simulación de la respuesta de la red ante nuevas entradas.

## 6. Análisis de la efectividad de la red.

### Patrones de Entrada/Salida

El primer paso es definir el problema. Para una red supervisada, como la red entrenada por retropropagación (*backpropagation*) que empleamos para clasificar defectos en soldaduras, esto significa construir un conjunto de vectores de entrada ( $\mathbf{p}_i$ ) y un conjunto de vectores de salidas deseadas denominados vectores objetivo ( $\mathbf{t}_j$ ).

Los patrones de entrada,  $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_R$ , tal y como se explicó en el apartado anterior de este capítulo, fueron creados calculando las 12 características ya comentadas extraídas de las regiones segmentadas como candidatas a defectos pertenecientes a 86 radiografías seleccionadas del catálogo de referencia del IIW. A este conjunto inicial de características se le aplicó un análisis de componentes principales para reducir la dimensionalidad.

Un procedimiento efectivo para reducir la dimensión de los vectores de entrada es el análisis de componentes principales (PCA). Esta técnica tiene tres efectos: ortogonalizar los componentes de los vectores de entrada (a fin de que no estén correlacionados unos con otros), ordenar los componentes ortogonales resultantes (componentes principales) de modo que aparezcan primero aquellos con mayor variabilidad, y eliminar aquellos componentes que contribuyen de menor manera a la variabilidad en el conjunto de datos. Su aplicación implica reducir el número de componentes requeridos, tanto como sea posible, sin pérdida de información relevante.

Un procedimiento estándar cuando se utiliza de forma conjunta el análisis de componentes principales y las redes neuronales es escalar las entradas de modo que siempre estén contenidas dentro de un rango especificado. En nuestro caso, los vectores de entrada generados con estos datos fueron normalizados para que tuvieran valor medio cero y desviación estándar unidad.

Por ser una ANN con aprendizaje supervisado, los vectores objetivo  $\mathbf{t}_j$  fueron contruidos por expertos inspectores que catalogaron cada candidato a defecto detectado como no defecto (falso candidato), inclusión de escoria, porosidad, grieta longitudinal y grieta transversal. Se trata de vectores de 5 componentes binarios, 0, 1, donde cada uno de dichos componentes se identifica con las 5 clases de defectos contemplados; un valor 1 en una determinada posición fuerza a que el resto de las componentes sean 0, siendo la posición del 1 indicativa del tipo de defecto

Un ejemplo de vectores de entrada y salida para un candidato a defecto detectado por el sistema y clasificado por los expertos como inclusión de escoria se muestra en la tabla 4.4.

### Conjuntos de datos para el entrenamiento

El siguiente paso es dividir el conjunto de datos en los subconjuntos de entrenamiento, validación y test. En este caso se realizaron dos divisiones distintas condicionadas por los diferentes algoritmos de entrenamiento utilizados.

La primera división supone la creación de tres subconjuntos. Por un lado, a partir del conjunto total de datos, se crearon, con una mitad, el subconjunto de entrenamiento, y con la mitad restante los de validación y test. La elección de los

Radiografía/ Defecto	Características					
IIW16						
	Ecc.	Orient.	Nº Euler	Diámetro E.	Solid.	Rect.
Inclusión de	0.648	48.28	1.00	32.11	0.80	0.519
Escoria	Redondez	Elong.	Aspecto	Índice Ext.	$e/A$	$L/A$
	2.524	0.987	1.287	1.429	0.221	0.323

$\mathbf{p}\{ 0.648, 48.28, 1.00, 32.11, 0.80, 0.519, 2.524, 0.987, 1.287, 1.429, 0.221, 0.323\}$   
 $\mathbf{t}\{ 0, 1, 0, 0, 0\}$

Tabla 4.4: Ejemplo de vectores de entrada y salida de la ANN.

elementos de cada subconjunto se realizó de forma entrelazada hasta completar la totalidad de datos, tal y como se ilustra gráficamente en la figura 4.43. El conjunto de entrenamiento se formó tomando un elemento cada dos de forma alternativa, y los conjuntos de validación y test se construyeron tomando uno de cada cuatro datos.

La otra división da lugar a la creación de dos subconjuntos; con la mitad de los datos se formó el subconjunto de entrenamiento, y con la otra mitad el subconjunto que se utilizará tanto para la validación como para el test.

### Arquitectura de la ANN

El siguiente paso es crear la red y entrenarla hasta que haya aprendido la relación las entradas ejemplo y las categorías objetivo. Existen varios aspectos que definen una red neuronal: su topología, el mecanismo de aprendizaje y el proceso de entrenamiento y ajuste.

La topología o arquitectura de las redes neuronales se refiere a la organización y disposición de las neuronas en la red formando capas o agrupaciones. En este sentido, los parámetros fundamentales de red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

La topología de la red utilizada en este trabajo se muestra en la derecha de la figura 4.44; su arquitectura se corresponde con la más comúnmente utilizada con el algoritmo de backpropagation. En la misma figura a la izquierda se esquematiza el modelo de neurona de entrada múltiple empleado, donde, como se aprecia, cada entrada individual  $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_R$  se pondera multiplicándola por los pesos  $w_{1,1}, w_{1,2}, \dots, w_{1,R}$ , de forma que la suma de las entradas ponderadas y las ganancias constituye la entrada a la función de transferencia,  $f$ , que produce la salida,  $a$ , de la neurona, expresiones 3.3 y 3.4

El clasificador no lineal de patrones se ha implementado utilizando una red neuronal artificial multicapa retroalimentada (ANN). Las neuronas se agrupan en tres capas: una de entrada, que recibe directamente la información de los patrones de entrada y cuyo número de neuronas viene obligado por la dimensión del vector de características elegido; una oculta con  $S_1$  neuronas, que utiliza una función de

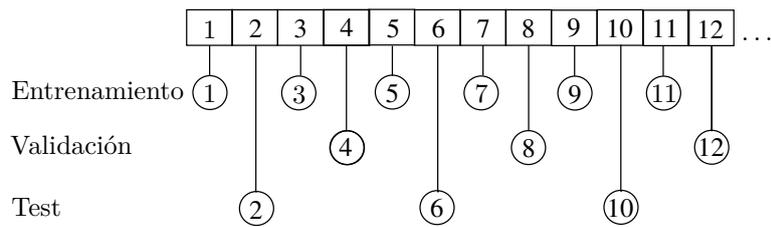


Figura 4.43: Selección de elementos de los conjuntos de entrenamiento, validación y test.

transferencia sigmoideal de tangente hiperbólica; y una capa de salida que utiliza una función de transferencia lineal, con un número de neuronas ( $S_2$ ) que viene determinado por el número de clases a reconocer (en nuestro caso  $S_2 = 5$ ).

Todas las señales en esta red se propagan hacia delante (*feedforward*) a través de las capas de la red. No existen conexiones hacia atrás (*feedback*) (ninguna salida de neuronas de la capa  $i$  se aplica a la entrada de neuronas de capas  $i - 1, i - 2, \dots$ ), y tampoco autorrecurrentes (salida de una neurona conectada a su propia entrada), ni laterales (salida de una neurona conectada a entradas de neuronas de la misma capa).

En la estructura de la red descrita han quedado algunos aspectos por definir. En concreto, no se ha especificado ni el número de neuronas de la capa de entrada ni el de la capa oculta. Esta elección debe ir encaminada a conseguir el mejor rendimiento de la red para clasificar cada uno de los defectos que nos hemos propuesto catalogar y la describiremos en apartados posteriores. En particular, el número de elementos de la capa de entrada ( $R$ ) vendrá condicionado por la pérdida de información discriminante permitida en relación con la reducción dimensional del análisis PCA.

### Entrenamiento de la ANN

Antes de proceder al entrenamiento de la red debemos poner pesos y ganancias a sus valores iniciales. Para ello utilizamos la función de Nguyen-Widrow [77], que calcula los pesos y ganancias iniciales de forma que la región activa de las neuronas se distribuya uniformemente por el espacio de entrada. Utilizar la inicialización de Nguyen-Widrow, en lugar de una inicialización aleatoria, generalmente acorta los tiempos de entrenamiento en más de un orden de magnitud.

Una vez que los pesos y ganancias de la red se han puesto a los valores iniciales, la red está preparada para su entrenamiento. El mecanismo de entrenamiento o aprendizaje, es decir, el proceso por el cual la red neuronal modifica sus pesos en respuesta a la información de entrada, sigue el criterio conocido como aprendizaje supervisado usando como método de aprendizaje el algoritmo de retropropagación del error (*backpropagation*), cuyos fundamentos se presentaron en el capítulo 3 de esta memoria.

El método del gradiente descendente que constituye la base de este algoritmo resulta generalmente demasiado lento para problemas prácticos. Hay un número de variaciones en el algoritmo base que se inspiran en otras técnicas de optimiza-

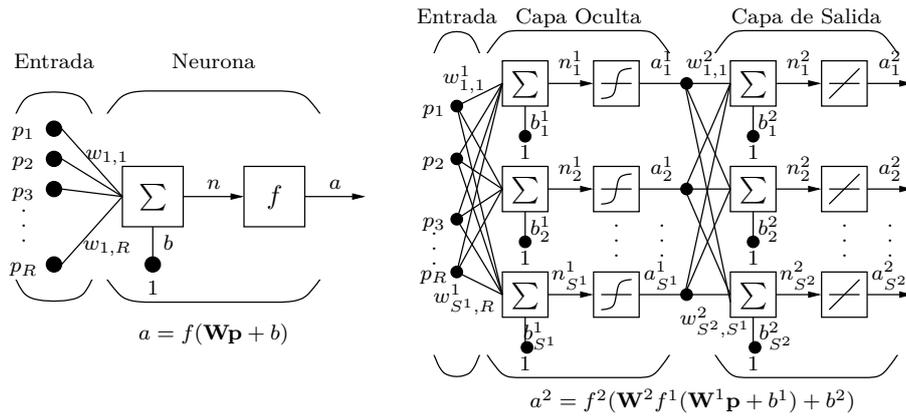


Figura 4.44: Modelo de neurona y arquitectura de la red

ción numérica estándar, tales como gradiente conjugado y método de Newton con rendimientos mayores, y que pueden converger de diez a cien veces más rápido.

El método de Newton es una alternativa al método del gradiente descendente para converger más rápidamente. Una forma básica de este algoritmo se puede escribir de la siguiente manera.

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{A}_k^{-1} \mathbf{g}_k \quad (4.27)$$

donde  $\mathbf{x}_k$  es un vector de pesos,  $\mathbf{A}_k^{-1}$  es la matriz Hessiana (segundas derivadas) del rendimiento y  $\mathbf{g}_k$  es el gradiente.

Desafortunadamente este método necesita procesar la matriz Hessiana, que supone un coste computacional elevado para una red neuronal con propagación hacia delante. Alternativamente, existe una clase de algoritmo que está basado en el método de Newton, pero que no requiere el cálculo de segundas derivadas. Se le conoce como método cuasi-Newton (o secante), y actualiza una matriz aproximada de la Hessiana en cada iteración del algoritmo. Una implementación de este método que ofrece buenos resultados es la denominada BFGS en honor a sus autores [25], que mejora las características de convergencia de otras aproximaciones.

Al igual que el método cuasi-Newton el algoritmo de Levenberg Marquardt está diseñado para entrenamientos rápidos sin tener que procesar la matriz Hessiana. Cuando la función de rendimiento tiene la forma de una suma de cuadrados, habitual en este tipo de redes, entonces la matriz Hessiana puede aproximarse como

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} \quad (4.28)$$

donde  $\mathbf{J}$  es la matriz Jacobiana que contiene las primeras derivadas de los errores de la red con respecto a los pesos y ganancias, y el gradiente puede calcularse como

$$\mathbf{g} = \mathbf{J}^T \mathbf{e} \quad (4.29)$$

siendo  $\mathbf{e}$  un vector de errores.

El algoritmo Levenberg-Marquardt utiliza una aproximación a la matriz Hessiana; parametrizada para un escalar  $\mu$ :

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} \quad (4.30)$$

donde  $\mathbf{I}$  es la matriz identidad. Cuando el escalar  $\mu$  es cero, la expresión coincide exactamente con el método cuasi-Newton utilizando la aproximación de la matriz Hessiana; cuando  $\mu$  es grande, la expresión calcula el gradiente descendente. La primera aplicación de este algoritmo al entrenamiento de redes neuronales está descrito en el trabajo de Hagan y Menhaj [36].

Las redes *backpropagation* adecuadamente entrenadas tienden a dar razonables respuestas cuando se le plantean entradas que nunca han visto. Generalmente, una nueva entrada conduce a una salida similar a la correcta para los vectores utilizados en el entrenamiento que son similares a la nueva entrada presentada. Esta generalización permite entrenar una red con un conjunto representativo de parejas entrada/objetivo y consigue buenos resultados sin entrenamiento de la red con todos los pares posibles entrada/salida.

En nuestro trabajo, hemos utilizado como procedimientos de entrenamiento de la red el método de Cuasi-Newton y el algoritmo de Levenberg-Marquardt. En ambos casos el proceso de entrenamiento se ha conducido por una función de rendimiento para optimizar el error cuadrático medio, limitándose el número máximo de iteraciones.

### Mejora de la generalización

En el proceso de entrenamiento se debe considerar, por una parte, un error de aprendizaje, que se suele calcular como el error cuadrático medio de los resultados proporcionados por la red para el conjunto de patrones de aprendizaje; con una red suficientemente grande, puede reducirse tanto como se quiera sólo con llevar a cabo más iteraciones. Y por otra parte, existe un error de generalización, que se puede medir empleando un conjunto de patrones de pruebas.

Un hecho experimental, fácilmente observable con cualquier simulador, es que si se entrena una red hasta alcanzar un error muy pequeño en el aprendizaje, la eficacia real del sistema o generalización se degrada. La explicación de este fenómeno es la siguiente. Al principio la red se adapta progresivamente al conjunto de aprendizaje, acomodándose al problema y mejorando la generalización. Sin embargo, en un momento dado el sistema se ajusta demasiado a las particularidades de los patrones empleados en el entrenamiento, aprendiendo incluso el ruido en ellos presente, por lo que crece el error que comete ante los patrones de prueba. A este efecto se le denomina sobre-aprendizaje o sobreajuste (*overfitting*). La red ha memorizado los ejemplos de entrenamiento, pero no ha aprendido a generalizar las nuevas situaciones.

La figura 4.45 muestra la respuesta de una red neuronal (1-20-1) que ha sido entrenada para aproximar una función seno con ruido; la función seno aparece como línea de puntos, las medidas del ruido se indican con el símbolo (+), y la respuesta de la red se refleja mediante la línea de trazo continuo. Claramente esta red ha sobreajustado los datos y no generalizará correctamente.

Un método para mejorar la generalización de la red es utilizar una que sea lo suficientemente grande para proporcionar un ajuste adecuado. Si se utiliza una red

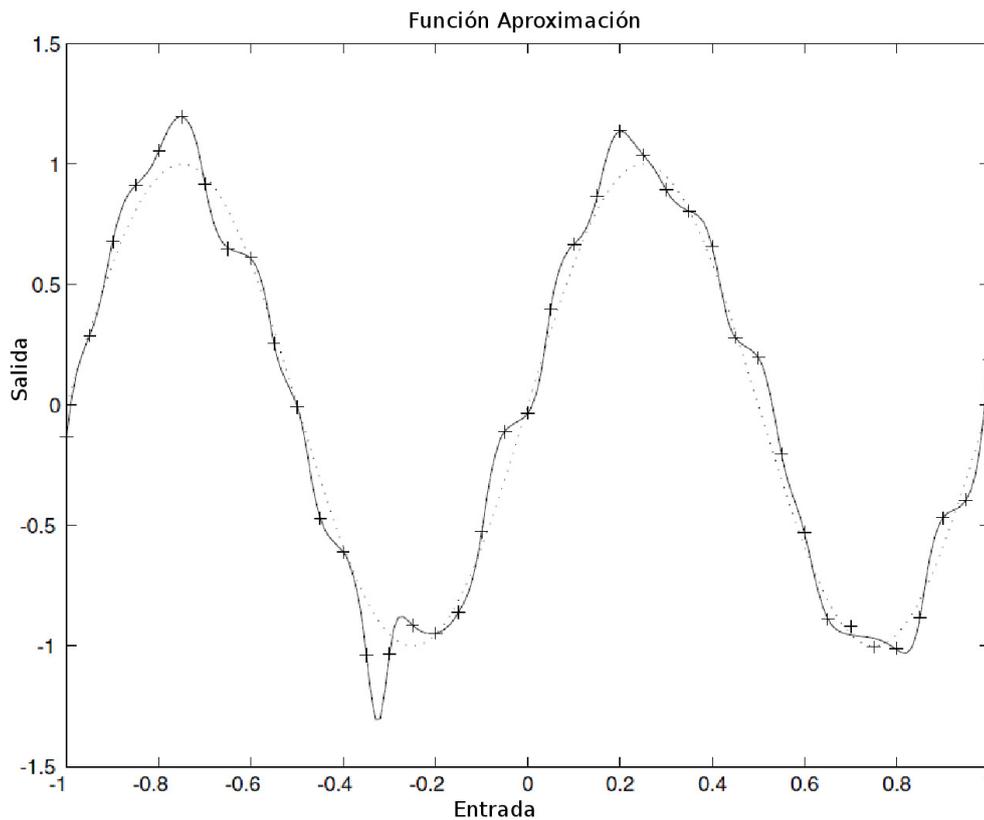


Figura 4.45: Efecto de sobreajuste.

demasiado pequeña no tendrá suficiente capacidad para ajustar los datos. Desafortunadamente, es difícil saber cómo de grande debería ser una red para una aplicación específica.

En este trabajo se han utilizado tres métodos para mejorar la generalización. El primer método se denomina regularización con función de rendimiento modificada, lo que implica modificar la función de rendimiento, que habitualmente se elige como la suma de los cuadrados de los errores de la red sobre el conjunto de entrenamiento.

La típica función de rendimiento utilizada para entrenar una red neuronal *feed-forward* es la suma de los cuadrados de los errores de la red:

$$F = \frac{1}{S} \sum_{j=1}^S (e_j)^2 = \frac{1}{S} \sum_{j=1}^S (t_j - a_j)^2 \quad (4.31)$$

donde  $t_j$  es el objetivo y  $a_j$  es la salida de la red, ambos definidos para la categoría  $j$ .

Es posible mejorar la generalización cambiando la función rendimiento mediante un término añadido que se obtiene ponderando la suma de los cuadrados de los pesos:

$$F_{mod} = \gamma F + (1 - \gamma) W_{sq} \quad (4.32)$$

donde  $\gamma$  es la razón de rendimiento, y con:

$$W_{sq} = \frac{1}{S} \sum_{j=1}^S (w_{ij})^2 \quad (4.33)$$

La utilización de esta función de rendimiento da lugar a que la red tenga pesos más pequeños, y esto fuerza a que la respuesta de la red sea más suave y menos proclive al sobreajuste.

El problema de la regularización consiste en la dificultad de determinar el valor óptimo para el parámetro razón de rendimiento ( $\gamma$ ). Si se hace este parámetro demasiado grande, se puede producir sobreajuste; por contra, si la razón es demasiado pequeña, no habrá un ajuste adecuado. Por tanto, deberá establecerse un procedimiento adecuado para determinar los parámetros óptimos de regularización de una forma automatizada.

El segundo método utilizado en este trabajo para mejorar la generalización asigna automáticamente los parámetros de la regularización. Se trata de la regularización Bayesiana con la estructura propuesta por David MacKay [61]. En esta estructura, se supone que los pesos y niveles de la red son variables aleatorias con una distribución específica. Los parámetros de regularización están relacionados con las varianzas desconocidas asociadas a estas distribuciones. Estos parámetros se pueden estimar utilizando técnicas estadísticas. Una discusión más detallada de la regularización Bayesiana se puede encontrar en el trabajo de Foresee y Hagan [28].

La figura 4.46 muestra la respuesta de la red neuronal entrenada con esta técnica de regularización para aproximar la función seno con ruido. A diferencia de lo mostrado en la figura 4.45 (red sobreajustaba), aquí se puede observar que la respuesta de la red está muy ajustada a la función seno (línea de puntos), y por tanto la red generalizará correctamente las nuevas entradas.

El tercer método empleado para mejorar la generalización se conoce como detención temprana (*early stopping o bootstrap*). En esta técnica, los datos disponibles se dividen en tres subconjuntos. El primer subconjunto es el de entrenamiento, que se utiliza para calcular el gradiente y actualizar los pesos y niveles de la red; en nuestro caso el 50% de los datos se utiliza como conjunto de entrenamiento. El segundo subconjunto es el de validación, que contiene el 25% de los datos. El error en el conjunto de validación se monitoriza durante el proceso de entrenamiento, y generalmente decrece durante la fase inicial del entrenamiento. Sin embargo, cuando la red comienza a ajustar los datos, el error en el conjunto de validación curiosamente comienza a crecer. Cuando el error de validación aumenta para un número determinado de iteraciones, el entrenamiento se detiene, y los pesos y niveles regresan al mínimo del error de validación. El tercer subconjunto, con el 25% de los datos, es el conjunto test que no se utiliza durante el proceso de entrenamiento.

La figura 4.47 muestra un gráfico de la respuesta de la red neuronal entrenada con la técnica de detección temprana para aproximar la función seno con ruido. A diferencia de lo mostrado en la figura 4.45, se puede observar que la red no sobreajusta los datos, aunque la respuesta no es tan suave como cuando se utilizó la regularización Bayesiana.

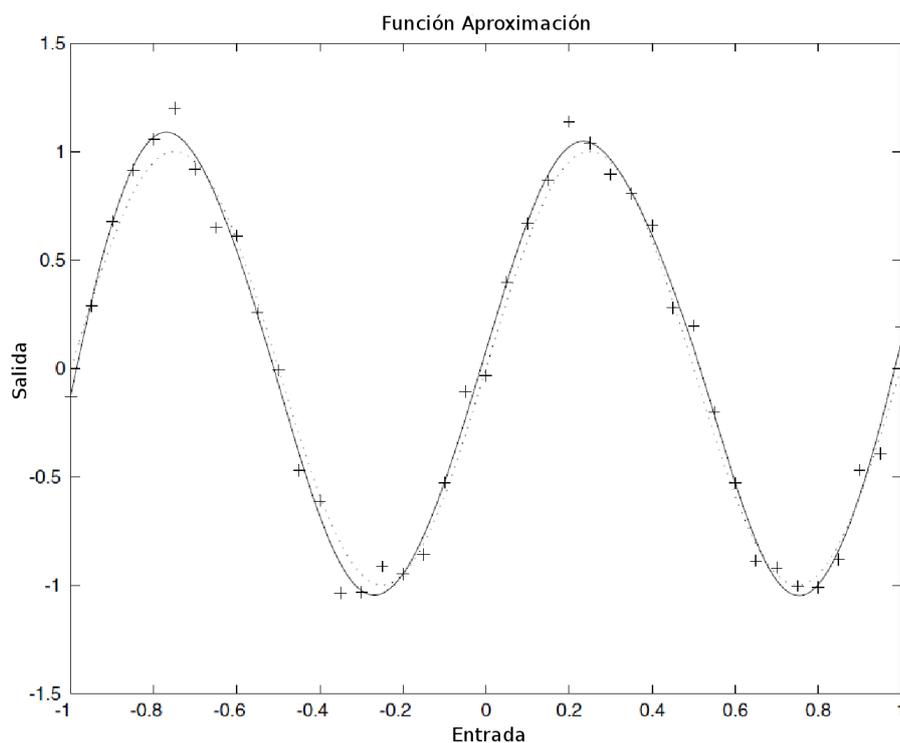


Figura 4.46: Regularización con función de rendimiento modificada.

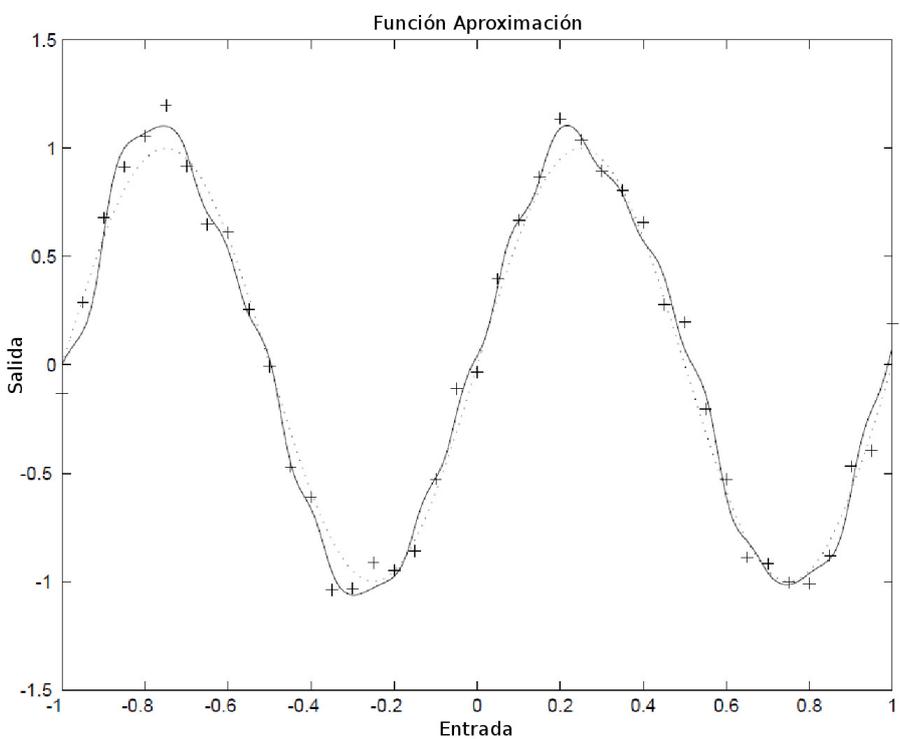


Figura 4.47: Regularización *Early Stopping*.

La evolución de los errores en la etapa entrenamiento se monitoriza durante los distintos procesos con gráficos como los que se muestran en las figuras 4.48 a 4.51 y que corresponden a una arquitectura de red construida con 10 neuronas en la capa de entrada, 15 neuronas en la capa oculta y 5 en la de salida, entrenadas con diferentes algoritmos y métodos de mejora de la generalización.

Los cuatro primeros gráficos de las figuras 4.48 y 4.49, corresponden a procesos de entrenamiento con algoritmo BFGS sin mejora de la generalización y con regularización mediante función de rendimiento modificada, respectivamente. Muestran cómo el error cuadrático medio comienza en valores altos y evoluciona disminuyendo hacia valores más pequeños; en otras palabras, la red está aprendiendo. Es importante señalar que, como se puede observar, cuando se realiza la regularización modificando la función de rendimiento, como se ilustra en la figura 4.49, se alcanzan antes valores constantes del error.

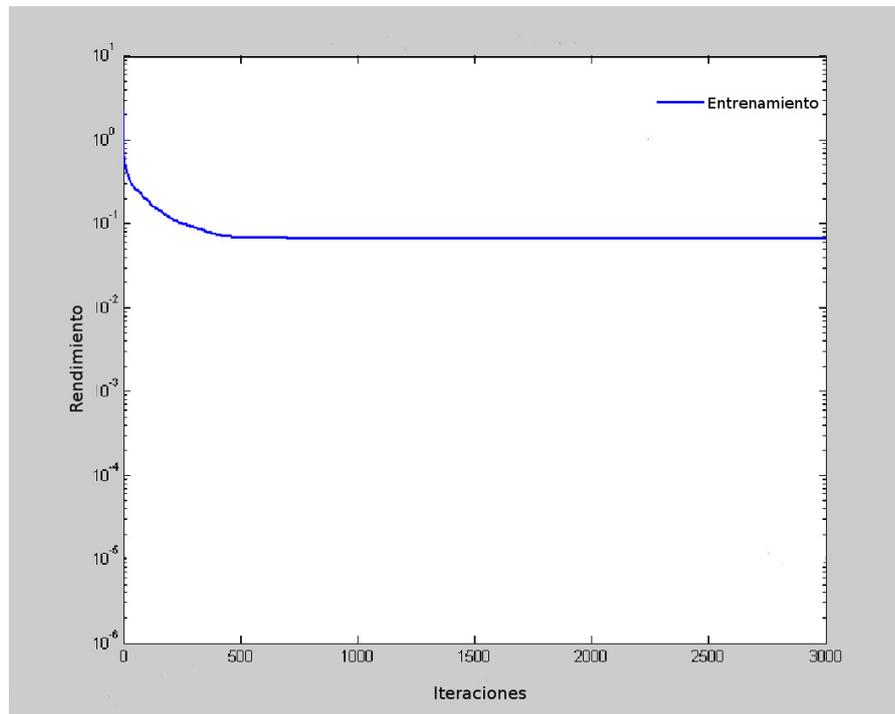
Los dos gráficos mostrados en la figura 4.50 corresponden a un proceso de entrenamiento con algoritmo BFGS y regularización Bayesiana, y muestran la evolución de la suma del error cuadrático en el conjunto de entrenamiento (SSE), de la suma de los cuadrados de los pesos (SSW), y del número de parámetros que están siendo utilizados por la red en cada instante. Como se puede observar, los tres parámetros alcanzan valores constantes cuando la red converge.

Los dos últimos gráficos de la figura 4.51 corresponden a un proceso de entrenamiento de la red con algoritmo Levenberg-Marquardt y mejora de generalización por Detección Temprana (*Early Stopping*), y muestran la evolución del rendimiento y del error cuadrático medio. Generalmente, cuando la red comienza a sobreentrenarse el valor del error de entrenamiento sigue disminuyendo, pero el error de validación comienza a aumentar. Cuando esto sucede en varias iteraciones consecutivas es el momento de detener el entrenamiento y tomar los parámetros de la red correspondientes al mínimo error de validación. En el caso que se muestra en la figura, el entrenamiento paró después de 14 iteraciones. El error de test no se utiliza durante el entrenamiento, pero resulta interesante su observación ya que un mínimo en el error de test en un punto muy diferente al del mínimo de validación puede indicar un pobre conjunto de datos de entrenamiento.

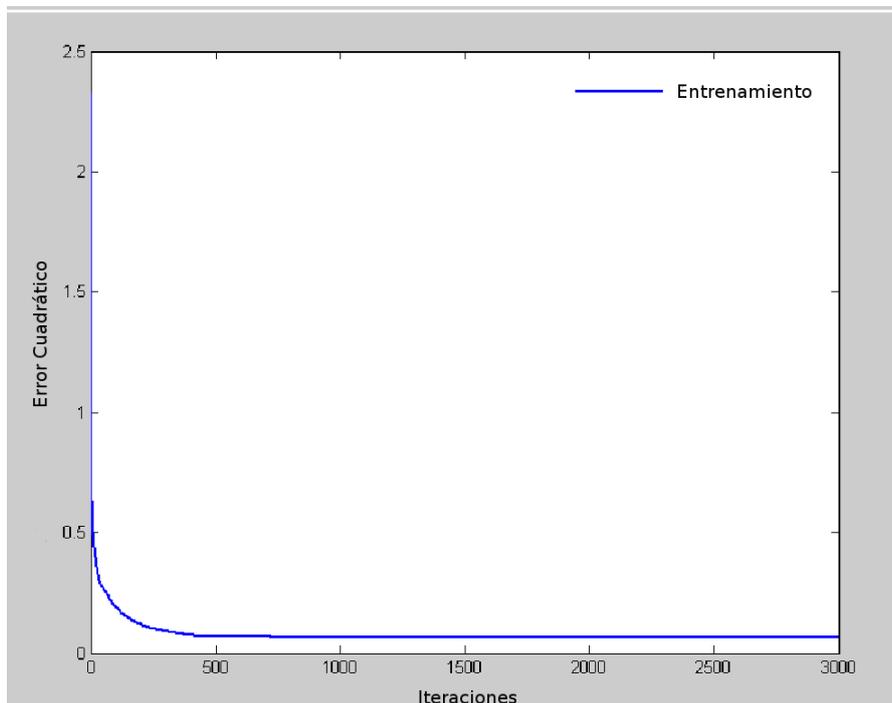
### Análisis de la efectividad de la ANN

En la estructura de la red elegida para nuestra aplicación hemos dejado algunos aspectos por definir. En concreto se ha de determinar: el número de neuronas en la capa de entrada y en la capa oculta, el algoritmo de entrenamiento y el método a utilizar para mejorar la generalización. Esta elección debe ir encaminada a conseguir el mejor rendimiento de la red para clasificar cada uno de los defectos que nos hemos propuesto catalogar.

El rendimiento de una red entrenada se puede medir, hasta cierto punto, por los errores en el entrenamiento, validación y los conjuntos de prueba. Un procedimiento que es con frecuencia utilizado para investigar con más detalle la respuesta de la red consiste en realizar un análisis de regresión entre la respuesta y los correspondientes

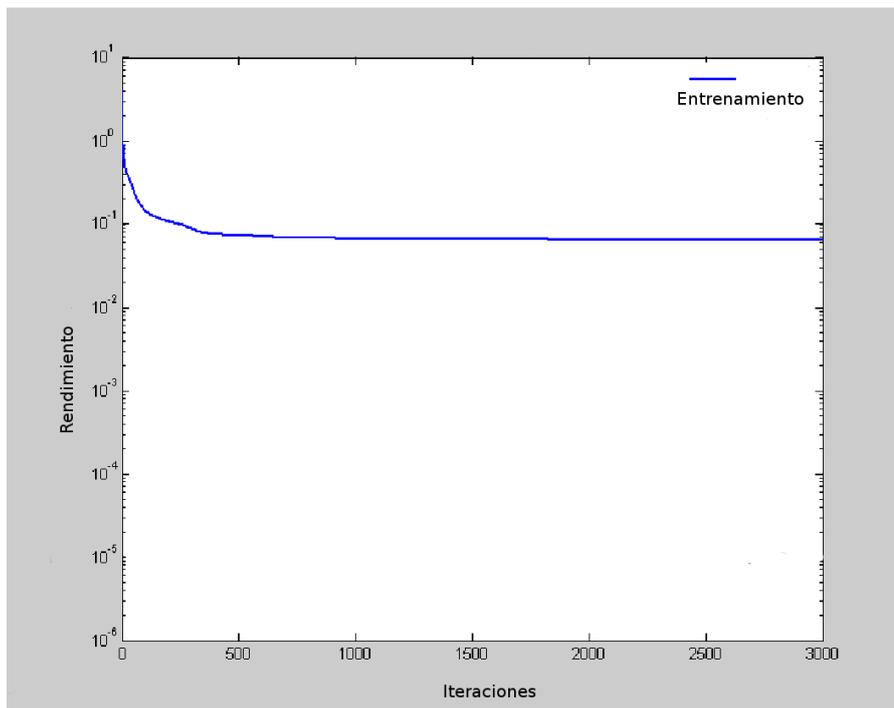


(a)

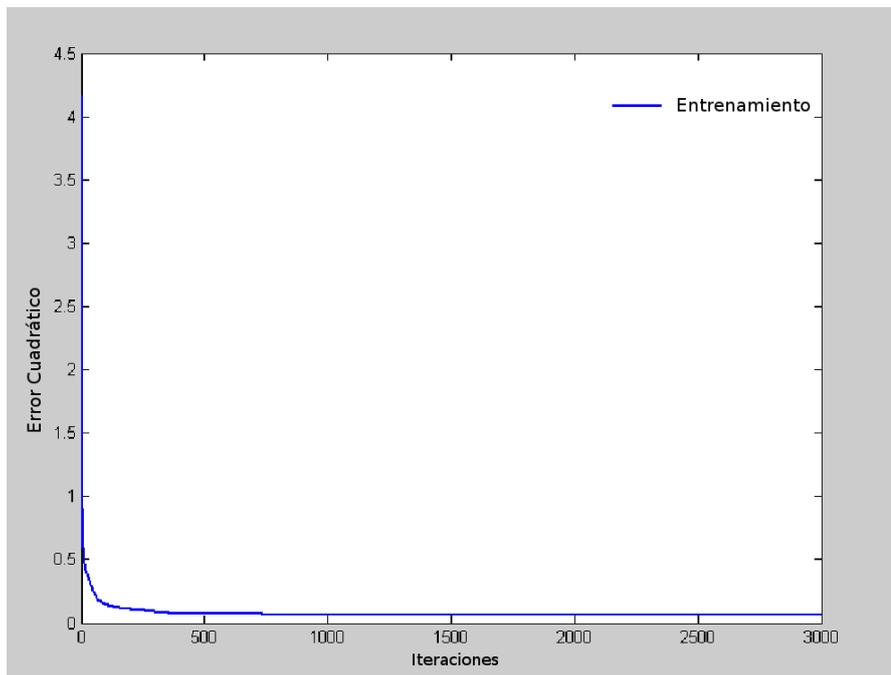


(b)

Figura 4.48: Proceso de entrenamiento con algoritmo BFGS sin mejora de la generalización: (a) Evolución del rendimiento; (b) Evolución del error cuadrático medio.

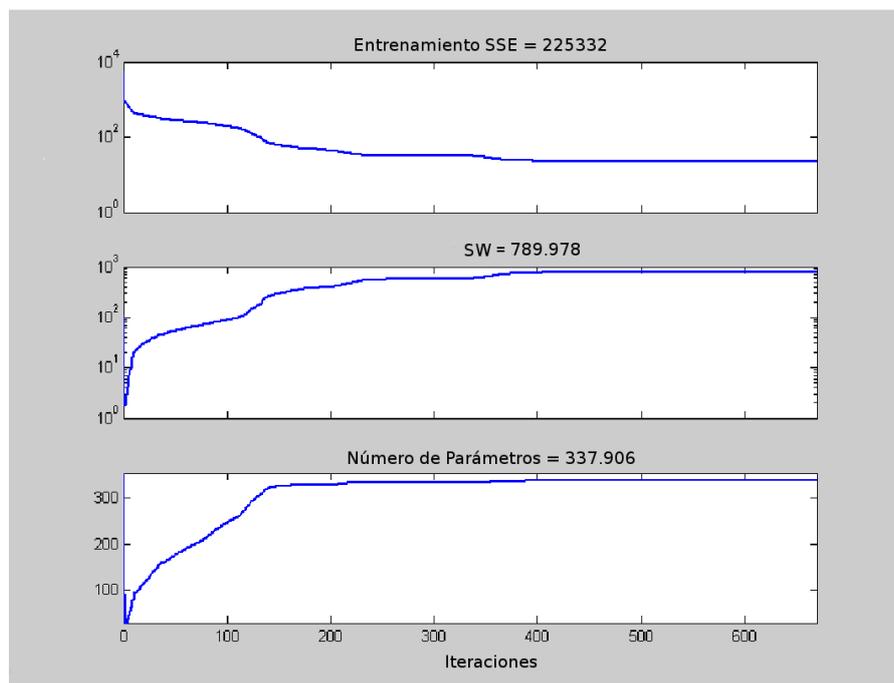


(a)

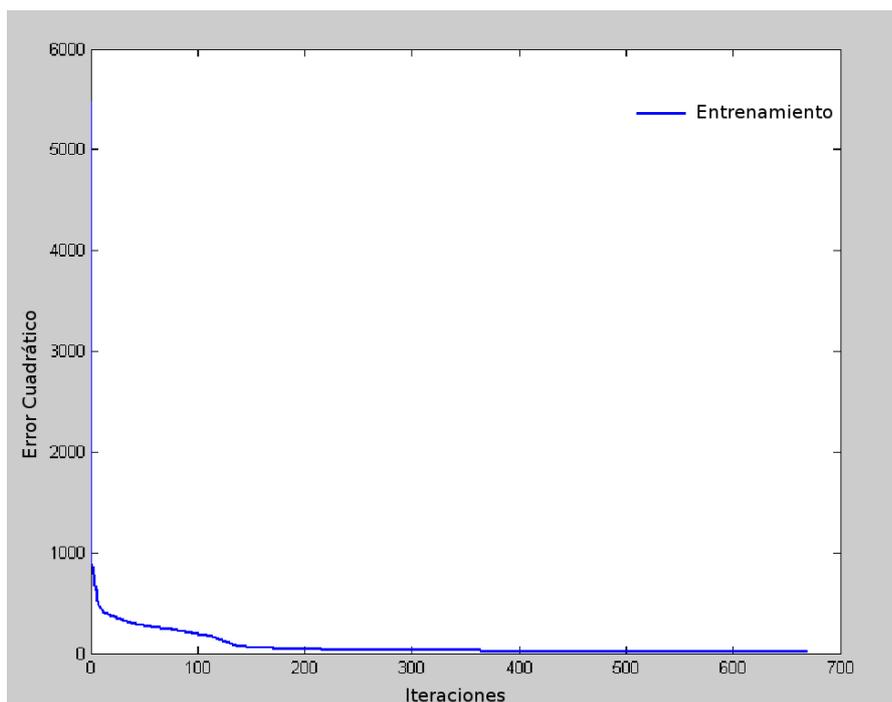


(b)

Figura 4.49: Proceso de entrenamiento con con algoritmo BFGS y regularización con función de rendimiento modificada: (a) Evolución del rendimiento; (b) Evolución del error cuadrático medio.

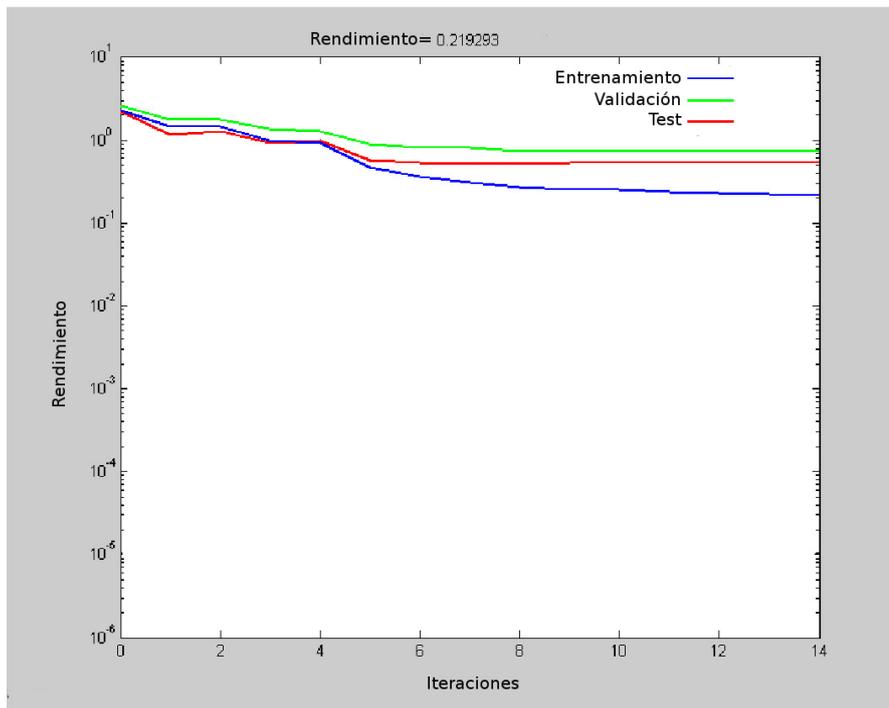


(a)

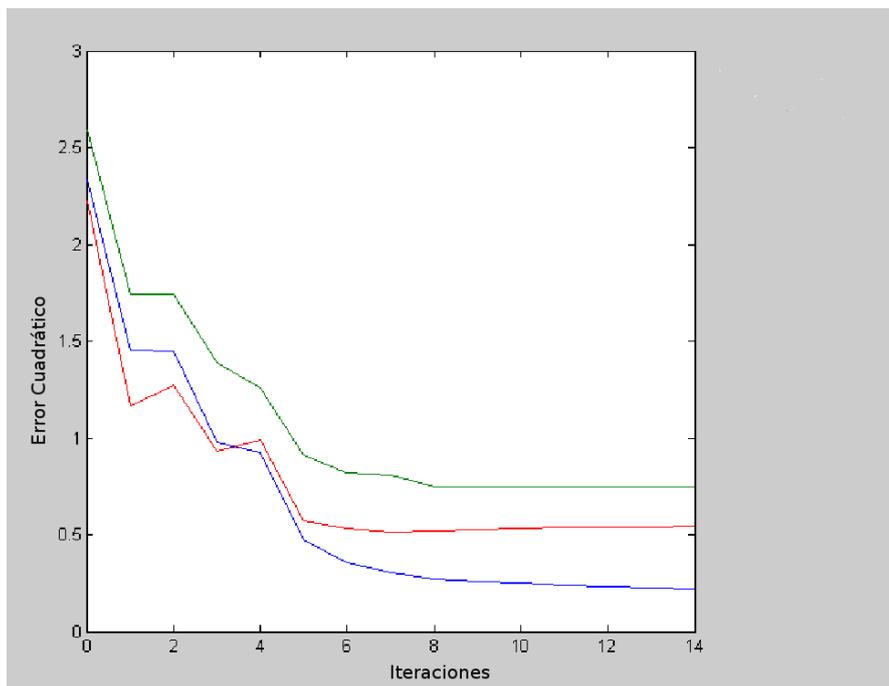


(b)

Figura 4.50: Proceso de entrenamiento con algoritmo BFGS y regularización Bayesiana: (a) Evolución del SSE, SSW y número efectivo de parámetros; (b) Evolución del error cuadrático medio.



(a)



(b)

Figura 4.51: Proceso de entrenamiento con algoritmo Levenberg-Marquardt y mejora de generalización por Detección Temprana (*Early Stopping*): (a) Evolución del rendimiento; (b) Evolución del error cuadrático medio.

objetivos. Los indicadores de la calidad de la respuesta son, por un lado, la pendiente y la ordenada en el origen de la mejor regresión lineal entre los objetivos y las salidas de las redes, y por otro lado el coeficiente de correlación  $R$ . Si se da un ajuste perfecto, es decir, cuando las salidas de la red resultan ser exactamente iguales a los objetivos o salidas deseadas, la pendiente debería ser 1, y la ordenada en el origen debería ser 0. Por su parte, el coeficiente de correlación obtenido entre las salidas y objetivos hasta que punto las variaciones en la salida se explican con los objetivos. Si este número es igual a 1, entonces hay una perfecta correlación entre objetivos y salidas, lo que indicaría un ajuste perfecto.

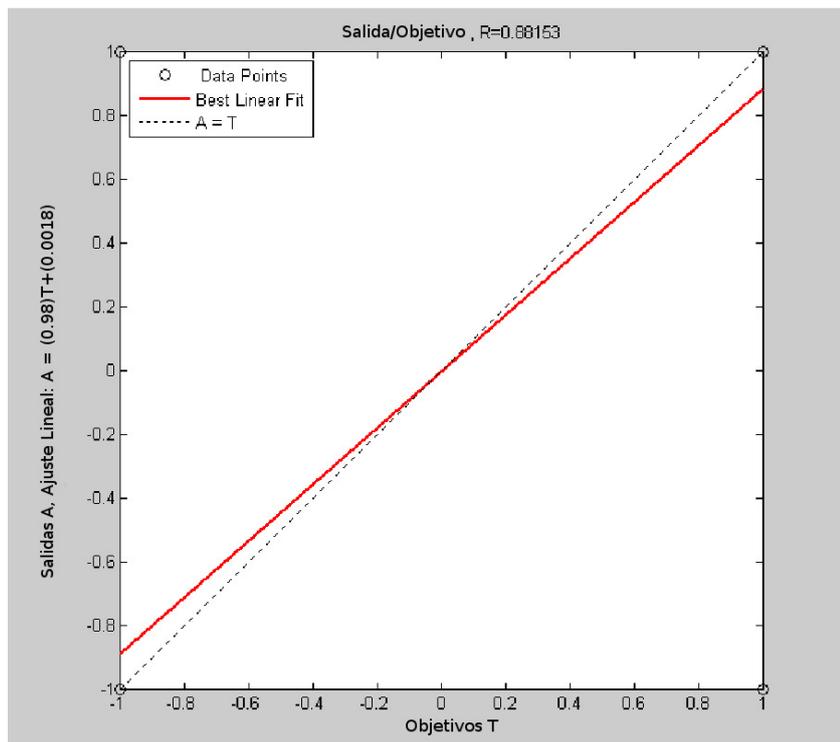
Las figuras 4.52, 4.53 y 4.54 muestran un ejemplo de este análisis de regresión para una de las configuraciones estudiadas de la AN, en concreto a la de la red construida con 10 neuronas en la capa de entrada, 15 neuronas en la capa oculta y 5 en la de salida y en la que se utilizó una regularización Bayesiana como método de mejora de la generalización. El mejor ajuste lineal está representado en las gráficas por líneas de trazo discontinuo, mientras que el ajuste perfecto (salida igual a objetivos) está indicado con línea de trazo continuo. Como se puede observar, las salidas obtenidas por la red para los tipos de defectos falso candidato, grieta transversal y grieta longitudinal, parecen seguir razonablemente bien a las salidas objetivo, obteniéndose valores de coeficientes de regresión próximos a 0.9. Por contra, las salidas obtenidas para el resto de defectos (inclusiones de escorias y porosidad) no están tan ajustadas y presentan coeficientes de regresión en torno a 0.6 y 0.7 respectivamente. Por tanto, estos tipos de defectos no están tan bien modelados y debería actuarse sobre la red, bien modificando su arquitectura introduciendo más neuronas en la capa oculta, o bien variando el método de mejora de la generalización utilizado.

#### 4.6.2 Clasificación de Defectos Utilizando un Sistema Adaptativo de Inferencia Neuro-Borrosa (ANFIS)

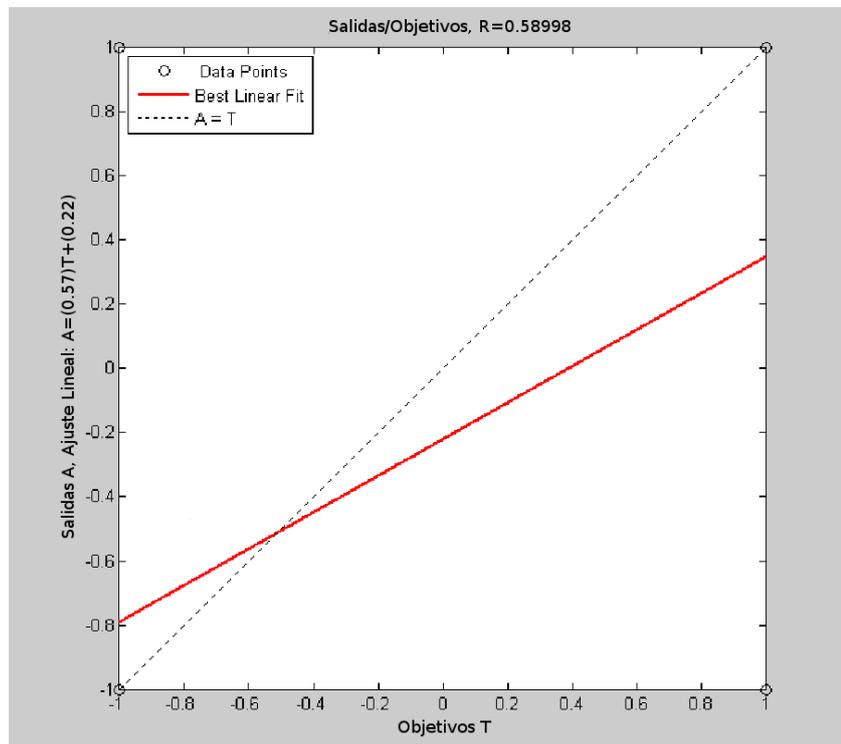
Desde su introducción, las redes ANFIS [42] se han aplicado con éxito para tareas de clasificación, control de procesos basados en reglas y problemas de reconocimiento de patrones como se indicó en el capítulo 3 de esta memoria. ANFIS es esencialmente una red adaptativa de funcionalidad equivalente a los sistemas de inferencia borrosa (FIS) y estructuralmente equivalente a una red neuronal artificial (ANN) y representa un enfoque de red neuronal útil para la solución de este tipo de problemas. Es capaz de construir un enlace entrada-salida basado en conocimiento humano y producir pares de datos entrada-salida.

El proceso de desarrollo de un clasificador de defectos utilizando una arquitectura ANFIS consta fundamentalmente de cinco etapas:

1. Obtención de los conjuntos de datos de entrada/salida.
2. Preparación de los conjuntos de datos para el entrenamiento.
3. Definición y creación de la estructura FIS.
4. Entrenamiento del sistema ANFIS.

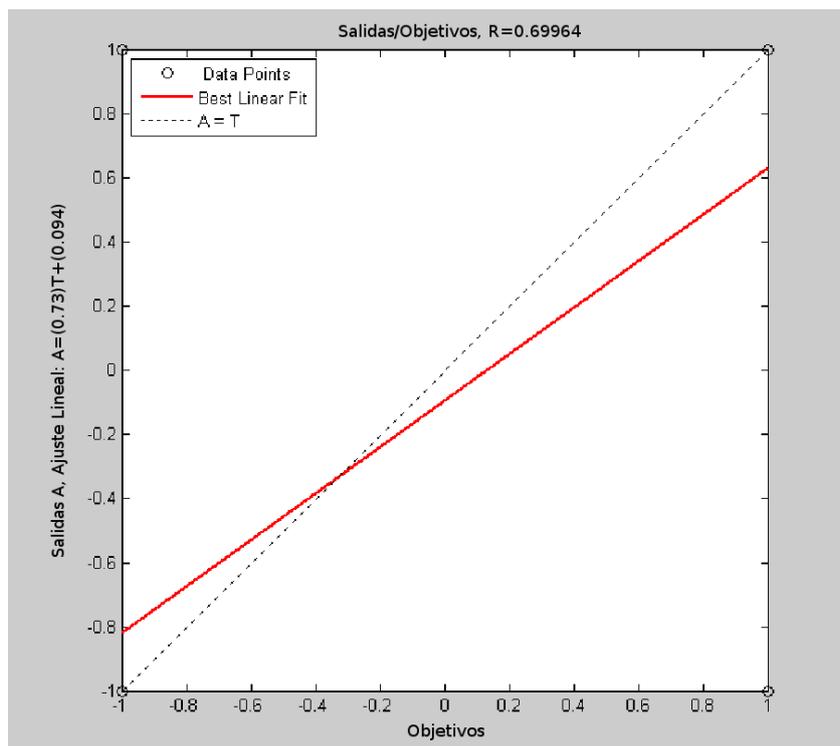


(a) Falso candidato

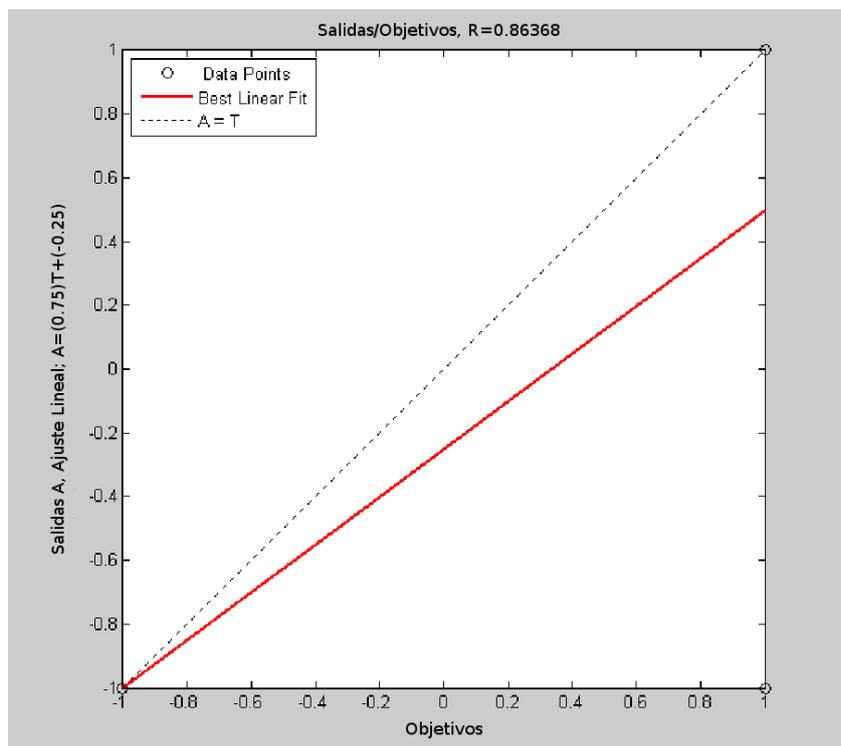


(b) Inclusiones de escoria

Figura 4.52: Análisis de regresión de la efectividad de una ANN con tres capas de 10-15-5 neuronas y regularización Bayesiana.

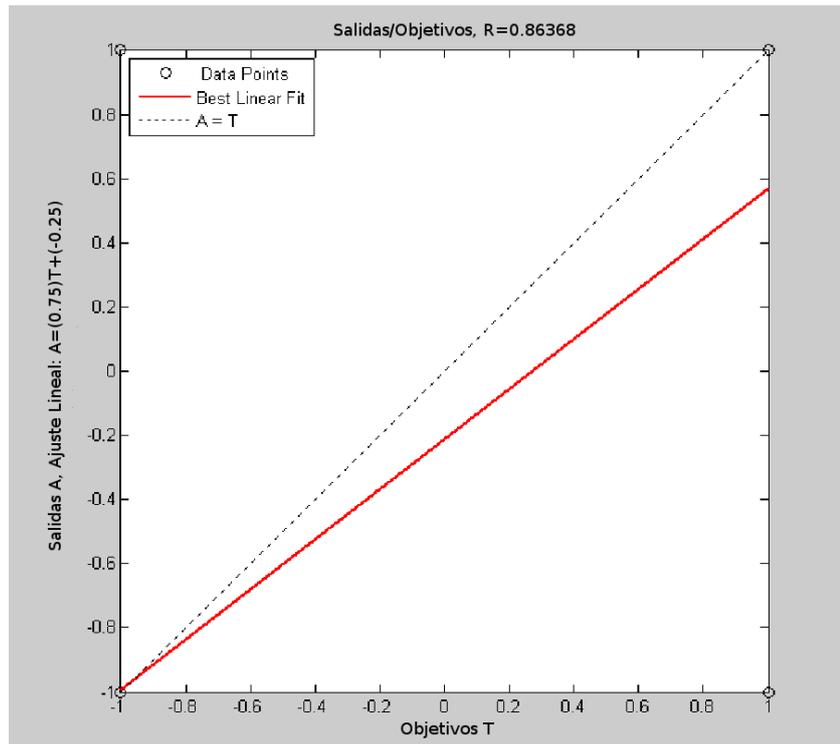


(a) Porosidad



(b) Grieta transversal

Figura 4.53: Análisis de regresión de la efectividad de una ANN con tres capas de 10-15-5 neuronas y regularización Bayesiana.



(a) Grieta longitudinal

Figura 4.54: Análisis de regresión de la efectividad de una ANN con tres capas de 10-15-5 neuronas y regularización Bayesiana.

## 5. Análisis de la efectividad del ANFIS.

### Conjuntos de datos entrada/salida

Las entradas al ANFIS son las características extraídas de las etapas previas del sistema. En este caso se construyó un vector tetra-dimensional formado con todas las combinaciones posibles de las 12 características estudiadas y definidas en la sección 4.5 de esta memoria, tomadas de cuatro en cuatro, y calculadas en las regiones segmentadas como candidatas a defectos pertenecientes a 86 radiografías seleccionadas del catálogo de referencia del IIW.

Por tratarse de una arquitectura con aprendizaje supervisado, los vectores objetivos ( $\mathbf{t}$ ) fueron construidos por expertos inspectores que catalogaron cada candidato a defecto como: no defecto (falso candidato), inclusión de escoria, porosidad, grieta longitudinal y grieta transversal. El patrón de salida es un vector de 5 elementos con dos únicos valores  $\{1, -1\}$  que expresan la catalogación del candidato en la categoría correspondiente a la posición que ocupa el 1 en dicho vector.

### Conjuntos de datos para entrenamiento

El conjunto de datos está formado en total de 375 valores combinados de entrada/salida, de los cuales el sistema utiliza los primeros 300 valores para el entrena-

miento, mientras que los otros 75 valores se utilizan como datos de comprobación necesarios para validar el modelo borroso de identificación. La elección de los datos que constituyen cada subconjunto se realizó de la forma que se ilustra en la figura 4.55. Esta división origina dos estructuras de datos (de entrenamiento y de validación) que se disponen en paralelo para entrar en los cinco sistemas ANFIS que, como se indica más adelante, se diseñaron para clasificar los defectos.

### Creación de la estructura FIS

Una vez definidos los conjuntos de datos de entrenamiento y validación hemos de especificar la estructura del sistema de inferencia borrosa (FIS). Esta estructura viene determinada por factores como el número de reglas y el número de funciones de pertenencia por cada entrada o los parámetros iniciales que especifican las formas de las funciones de pertenencia asociadas a las entradas y a las salidas.

Esta especificación se puede hacer por varios métodos, de los cuales los más utilizados son la llamada partición por rejilla (*grid partition*) y el de clusterización sustractiva (*subtractive clustering*). El primer procedimiento crea una estructura basada en un número de fijo de funciones de pertenencia utilizando la técnica de agrupamiento de datos *Fuzzy C-Means* (FCM) [7], mientras que el segundo particiona los datos en grupos o *clústers* basándose en la técnica utilizada por Chiu [15], y crea una estructura FIS con el mínimo número de reglas que se necesiten, de forma que se distingan las cualidades borrosas asociadas a cada *cluster*.

El proceso de inferencia borrosa, como vimos en el capítulo anterior, puede ser de dos tipos: inferencia tipo Mamdani y tipo Sugeno. Si bien los dos métodos siguen la misma idea básica, los sistemas borrosos tipo Sugeno se prestan mejor a técnicas adaptativas, ya que cualquier regla contiene más información al ser su representación más compacta y computacionalmente más eficiente que las de tipo Mamdani.

En nuestro caso elegimos una estructura FIS tipo Sugeno como estructura inicial para el entrenamiento del ANFIS, usando una partición de rejilla de los datos que proporciona tres funciones generalizadas de pertenencia tipo campana de Gauss para cada una de las cuatro entradas (en total doce por cada estructura FIS) y una función de pertenencia de tipo lineal para la salida. De esta forma la estructura generada contiene 16 reglas borrosas con 104 parámetros.

La estructura FIS tiene implícito el grave problema de la dimensionalidad, al producirse la propagación de un número excesivo de reglas cuando el número de entradas es moderadamente grande (superior a cinco). Esta es la razón por la que en nuestro sistema hemos elegido sólo cuatro entradas a esta arquitectura, definidas a partir de las 12 características extraídas de cada candidato a defecto.

Las cuatro entradas numéricas a la arquitectura se transformarán en sendos grados de pertenencia al compararse con los antecedentes, que ponderarán la medida en que cada antecedente participará en la implicación borrosa. Al haber más de una entrada, se necesita aplicar operadores borrosos para combinar la contribución de cada uno de los antecedentes en un único valor. Se trata de operadores AND borrosos, que en nuestro caso se implementaron mediante el producto aritmético de los grados de pertenencia.

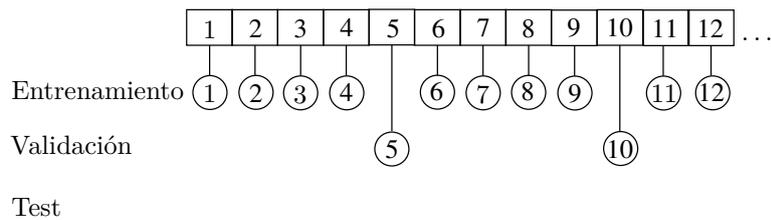


Figura 4.55: Selección de elementos de los conjuntos de entrenamiento y validación.

En cuanto al operador de implicación representativo de las reglas del sistema, de nuevo se ha elegido en nuestra aplicación el producto aritmético, de forma que los factores numéricos resultantes de la comparación de las entradas con los antecedentes de cada regla se toman como factores multiplicativos que se aplican a las distribuciones de pertenencia de los consecuentes. La agrupación de las salidas de cada regla en un único conjunto borroso se lleva a cabo aplicando el operador máximo (OR) a los valores de pertenencia de las distribuciones resultantes de cada una de dichas reglas.

La última etapa del bloque de inferencia borrosa consiste en un proceso de *desborrosificación* por el que se transforma la distribución borrosa resultante de la evaluación del conjunto de reglas en un único valor numérico. Existen diversas formas de realizar esta desborrosificación, entre las que se pueden destacar por su frecuencia de uso el método del centroide y el de la media ponderada. En nuestra aplicación nos hemos decantado por el segundo de ellos para implementar la desborrosificación.

A modo de resumen, la figura 4.56 ilustra la arquitectura ANFIS empleada en este trabajo para clasificar defectos de soldadura. Se trata de cinco sistemas neuroborrosos, uno por cada categoría de clasificación, con cuatro entradas cada uno y un conjunto específico de reglas de inferencia tipo Sugeno.

### Entrenamiento del sistema ANFIS

El método de aprendizaje neuro-adaptativo trabaja de forma similar a como lo hacen las redes neuronales. Las técnicas de aprendizaje neuro-adaptativas proporcionan un método de modelado borroso para aprender de la información de un conjunto de datos. Entonces, la lógica borrosa procesa los parámetros de la función de pertenencia que mejor permite al sistema de inferencia asociado seguir los datos de entrada/salida.

El aprendizaje que ANFIS emplea para ajustar los parámetros de las funciones de pertenencia puede consistir en la mera aplicación del algoritmo de retropropagación para dichos parámetros. En nuestro caso hemos empleado un procedimiento híbrido en el que el algoritmo de *backpropagation* (gradiente descendente) se emplea para optimizar los parámetros asociados con las funciones de pertenencia de las entradas (antecedentes), mientras que un segundo procedimiento de ajuste por mínimos cuadrados se encarga de determinar los parámetros lineales de las funciones de pertenencia de las salidas (consecuentes de las reglas).

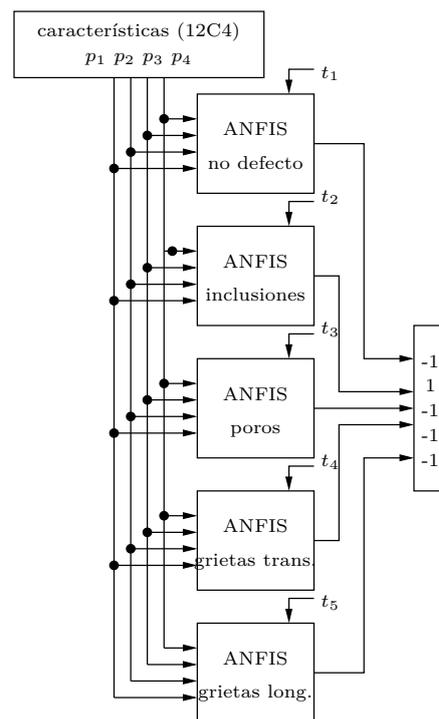


Figura 4.56: Arquitectura del sistema clasificador de defectos de soldadura basado en ANFIS.

De una forma general, el proceso de aprendizaje del ANFIS intenta desplazar los valores de los parámetros de las funciones de pertenencia de forma proporcional a la derivada del error respecto a ese parámetro (gradiente descendente). Esto lo hace calculando la suma de los errores cuadráticos medios (diferencia entre la salida deseada y la salida de la red). Utiliza el gradiente de ese error (indica hacia donde se produce el mayor incremento del error), en negativo, para minimizar el error. Para conseguirlo, multiplica cada parámetro del antecedente por un valor proporcional al gradiente respecto de ese parámetro de entrada (en negativo). Ese valor proporcional es lo que se conoce como factor de aprendizaje. Con eso se van ajustando los parámetros del antecedente de forma que se va reduciendo el error producido por el sistema ANFIS. El principal problema es que cuando el gradiente del error es muy pequeño hacen falta muchas iteraciones para disminuir el error.

Los parámetros que definieron el proceso de entrenamiento seguido y que determinan tanto el criterio de parada como la validación del sistema fueron;

- número de iteraciones (*epochs*) de entrenamiento: 10
- error de tolerancia: 0
- tamaño de paso inicial: 0.01
- tasa de incremento de paso: 1.1
- tasa de decremento del tamaño de paso: 0.9

Con estos datos, el proceso de entrenamiento se detiene en caso de que se alcance el número de iteraciones fijadas o se llegue al error objetivo.

Generalmente se persigue que el perfil del tamaño de paso sea una curva que crece inicialmente, alcanza algún valor máximo y luego decrece para el resto del entrenamiento. Este perfil ideal se consigue ajustando el tamaño de paso inicial y las tasas de crecimiento y decrecimiento. La forma de ajuste de las funciones de las tasas de error utilizada fue la siguiente: si el error decrece cuatro veces consecutivas, el tamaño de paso se aumenta multiplicándolo por 1.1 (tasa de incremento de paso); si el error tiene dos combinaciones seguidas de un incremento y una reducción, el tamaño de paso se reduce multiplicándolo por 0.9 (tasa de decremento).

Elegido el método de entrenamiento y fijados los parámetros del proceso, se inicia el mecanismo de aprendizaje híbrido con validación para la optimización paramétrica y lo dejamos evolucionar durante 10 iteraciones. Las funciones de pertenencia finales obtenidas en nuestra aplicación se muestran en la figura 4.57.

Por último, la figura 4.58 representa la evolución de la raíz del error cuadrático medio (RMSE) a lo largo de un entrenamiento de la red, en donde dicho error para el conjunto de entrenamiento se muestra en azul y para el conjunto de validación se representa en verde.

### Análisis de la efectividad del ANFIS

Para probar la capacidad de generalización del sistema de inferencia borrosa, se utilizaron los datos de comprobación, distintos a los de entrenamiento aunque tienen el mismo formato. Los datos de comprobación son importantes para las tareas de aprendizaje sobre todo en aquellos sistemas en los que el número de entradas es grande y/o los datos son ruidosos.

El rendimiento del sistema se puede medir, hasta cierto punto, por los errores en el entrenamiento, es decir, la diferencia entre el valor de salida que se proporciona en el conjunto de entrenamiento y la salida que da el sistema de inferencia borroso para las mismas entradas, y por los errores de validación, es decir, la diferencia entre el valor de salida que se proporciona en el conjunto de prueba y la salida que da el sistema de inferencia borroso para las mismas entradas. La figura 4.59 muestra estos gráficos.

Una opción que es con frecuencia utilizada para investigar con más detalle la respuesta del sistema es realizar un análisis de regresión entre la respuesta y los correspondientes objetivos. El coeficiente de correlación obtenido entre las salidas y objetivos mide el grado de concordancia entre las variaciones en la salida y los objetivos. Si este número es igual a 1, entonces hay una perfecta correlación entre objetivos y salidas, lo que indica un ajuste perfecto.

Para proporcionar esta visión sobre el rendimiento del sistema de clasificación de defectos en soldadura propuesto, sobre el mismo conjunto de datos de prueba se evaluó la eficacia de un ANFIS para clasificar las 5 clases de heterogeneidades, utilizando todas las combinaciones posibles de las 12 características calculadas de los candidatos a defectos segmentados agrupadas de cuatro en cuatro. Las figu-

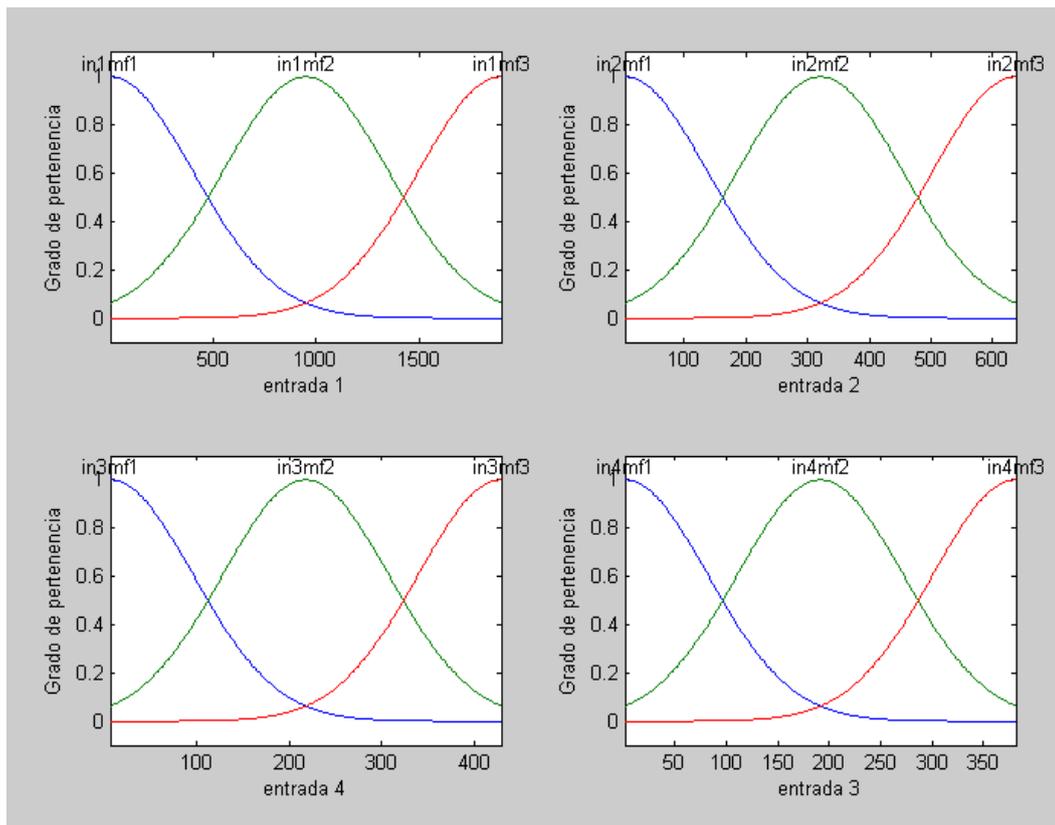


Figura 4.57: Funciones de pertenencia finales.

ras 4.60, 4.61 y 4.62, muestran un ejemplo de este análisis de regresión para una de las múltiples configuraciones estudiadas del ANFIS, en concreto la del sistema cuyo vector de entrada está formado por las siguientes características: elongación, rectangularidad, excentricidad y *solidity*. El mejor ajuste lineal está representado en las gráficas por líneas de trazo discontinuo, mientras que el ajuste perfecto (salida igual a objetivos) está indicado con línea de trazo continuo. Como se puede observar, las salidas obtenidas por la red para los tipos de defectos falso candidato, grieta transversal y grieta longitudinal, parecen seguir razonablemente bien a las salidas objetivo, obteniéndose valores de coeficientes de regresión próximos a 0,9. Por contra, las salidas obtenidas para las inclusiones de escorias y porosidad no están tan ajustadas y presentan coeficientes de regresión en torno a 0.7 y 0.8 respectivamente.

Un análisis completo de los coeficientes de correlación obtenidos por cada una de las combinaciones evaluadas nos dará la configuración óptima del clasificador de defectos que complete la última etapa de nuestro sistema.

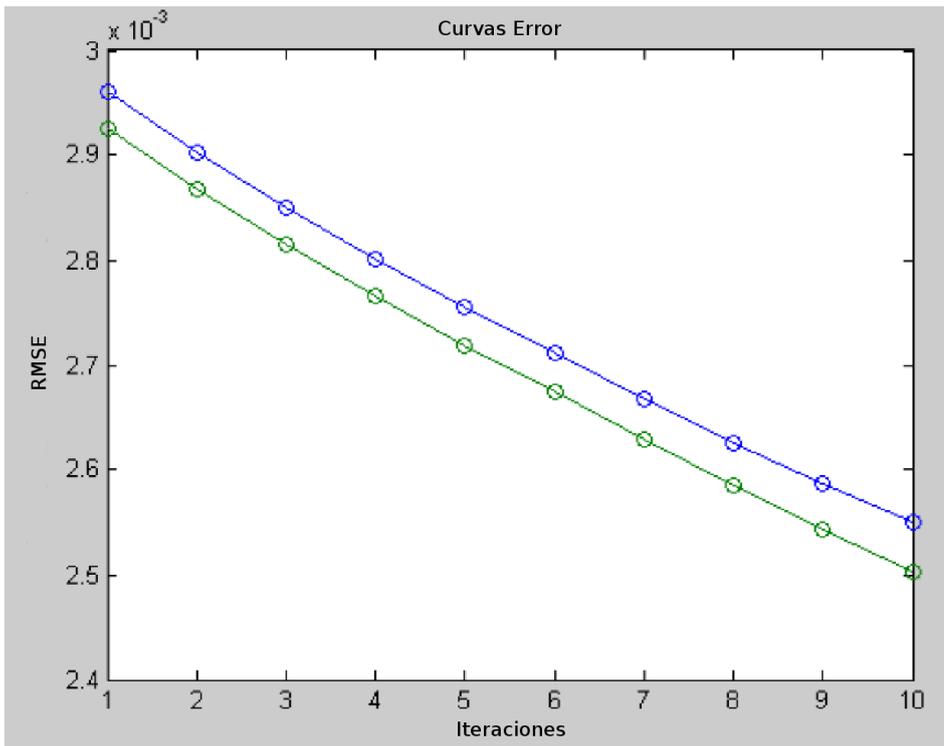


Figura 4.58: Curvas de error.

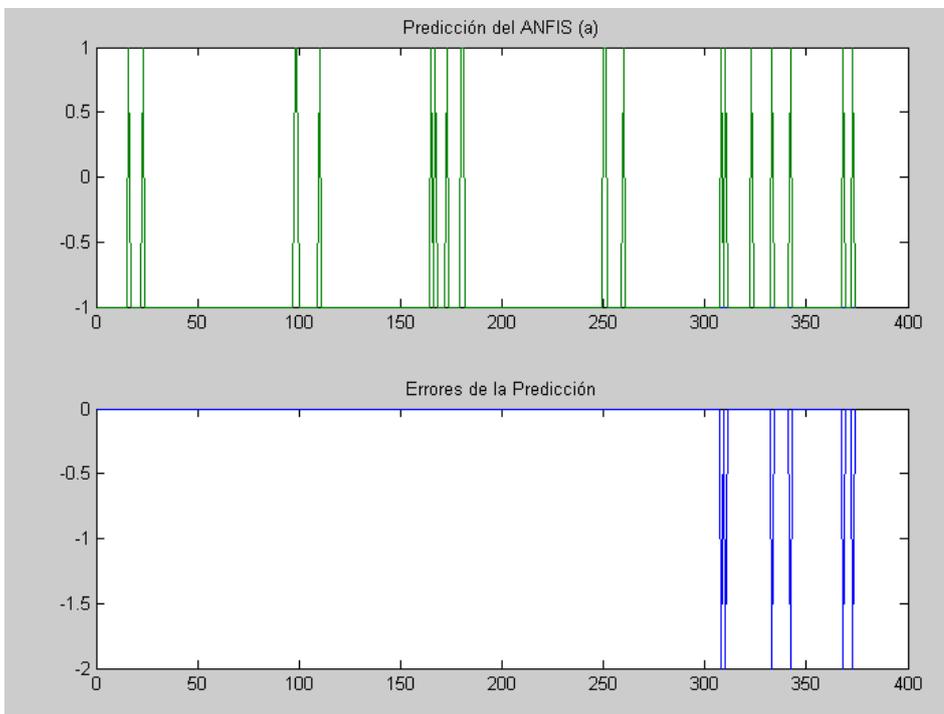
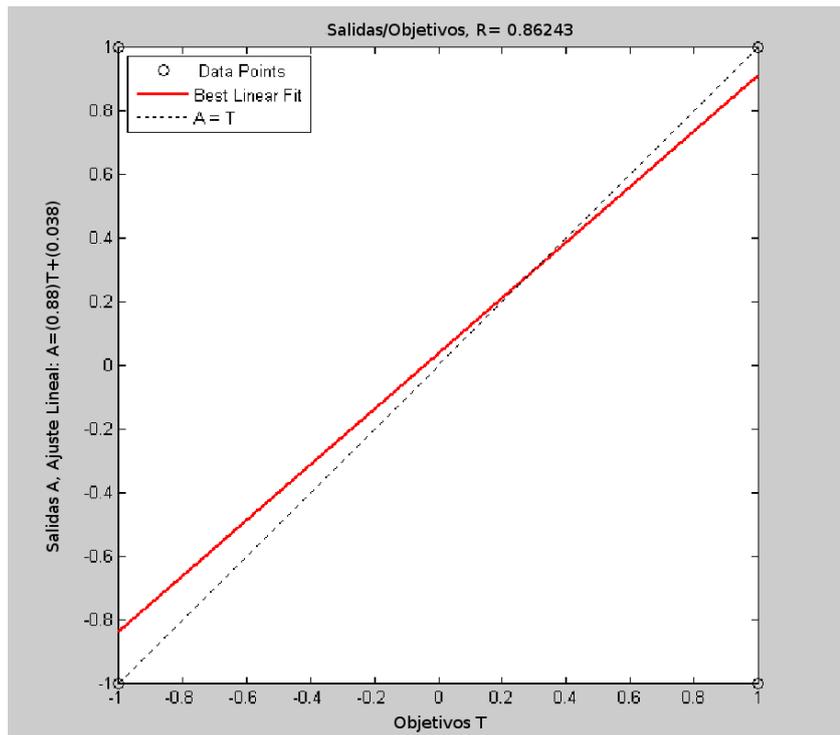


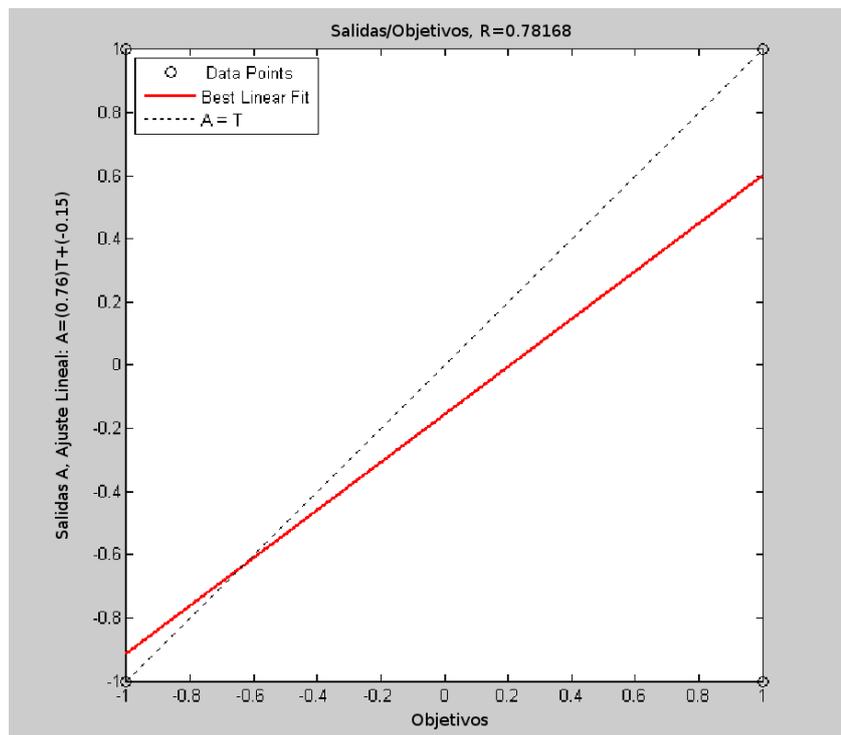
Figura 4.59: Salida FIS frente Salida objetivo.

### 4.7 Sumario

En este capítulo se ha realizado la exposición y justificación de las técnicas y algoritmos desarrollados para completar nuestra propuesta para el diseño de un sistema de inspección automática de imágenes radiográficas de uniones soldadas. En dicha propuesta hemos desarrollado y adaptado soluciones innovadoras para las etapas más críticas, que son las de segmentación del cordón de soldadura, detección de candidatos a defectos, selección de características relevantes e identificación de los mismos. Estas propuestas se concretan, en primer lugar, en tres procedimientos para la segmentación del cordón de soldadura; al primero de ellos le hemos denominado *técnica de segmentación basada en perfiles*, al segundo procedimiento *técnica de segmentación progresiva*, y al último procedimiento lo hemos denominado *técnica de segmentación por etiquetado de componentes conectados*. Para la etapa de detección de heterogeneidades hemos seguido un procedimiento análogo al último de los propuestos en la etapa anterior. En cuanto a la selección de características relevantes de cara a la adecuada caracterización de las heterogeneidades detectadas para su posterior clasificación hemos realizado dos aportaciones. La primera propuesta la hemos denominado *selección por categorías morfológicas*, y a la segunda propuesta la hemos denominado *selección mediante análisis de componentes principales (PCA)*. Por último, hemos abordado la clasificación de los candidatos a defectos a través de dos propuestas encuadradas en el ámbito de los sistemas neuroborrosos, y que supongo uno de los aspectos distintivos de este trabajo. Por un lado, hemos desarrollado un clasificador no-lineal de patrones utilizando una red neuronal artificial (ANN), y como una segunda propuesta, un sistema adaptativo de inferencia neuro-fuzzy (ANFIS). En los dos casos, se han estudiado distintas configuraciones de los sistemas en la búsqueda de las soluciones más eficientes, estudio que es objeto del capítulo 5 de esta memoria.

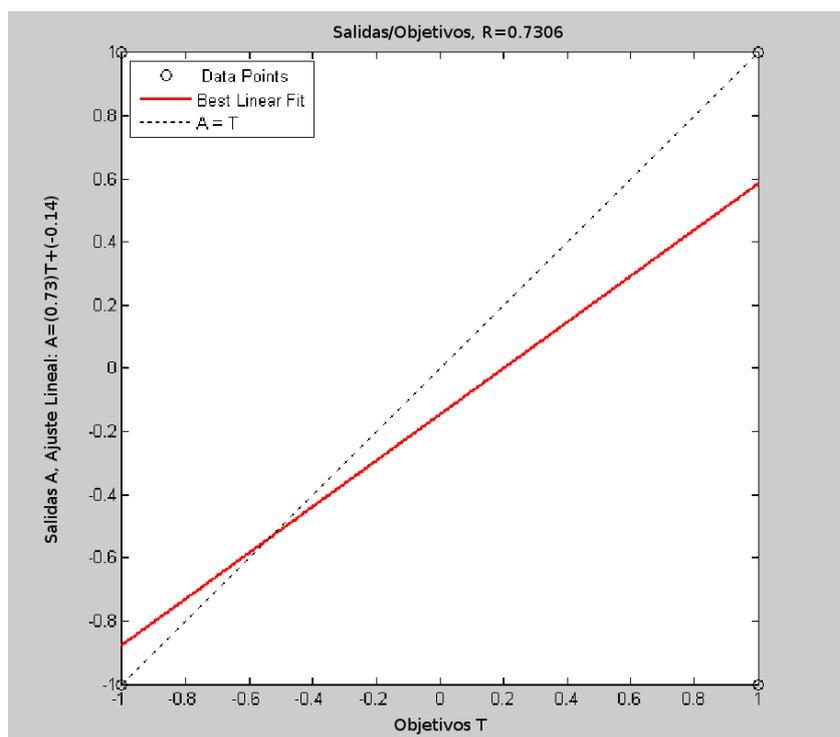


(a) Falso candidato

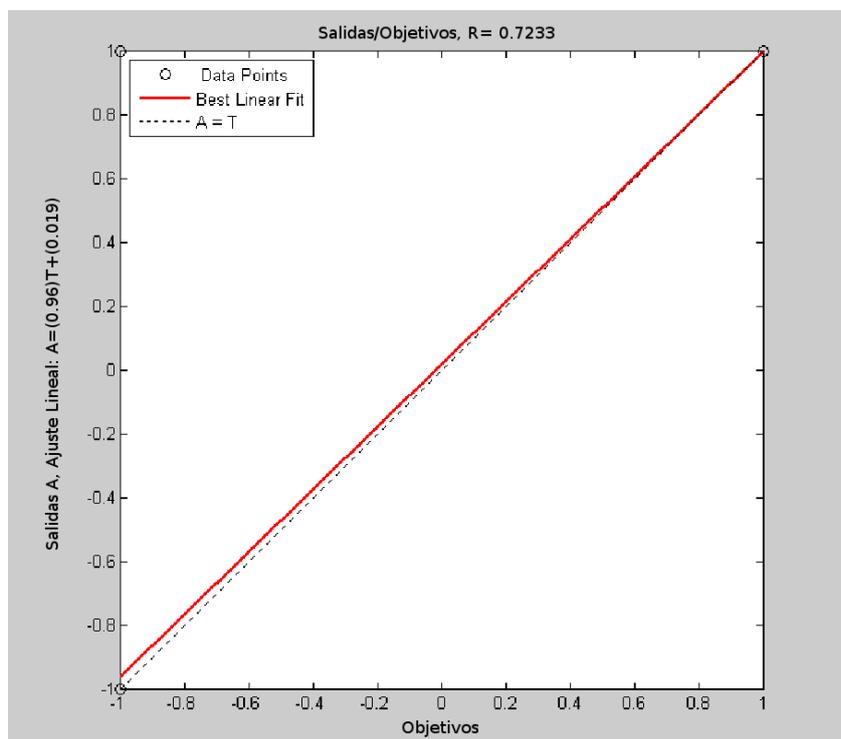


(b) Inclusiones de escoria

Figura 4.60: Análisis de regresión de la efectividad de un ANFIS con vector de entrada formado por las siguientes características: elongación, rectangularidad, excentricidad y *solidity*

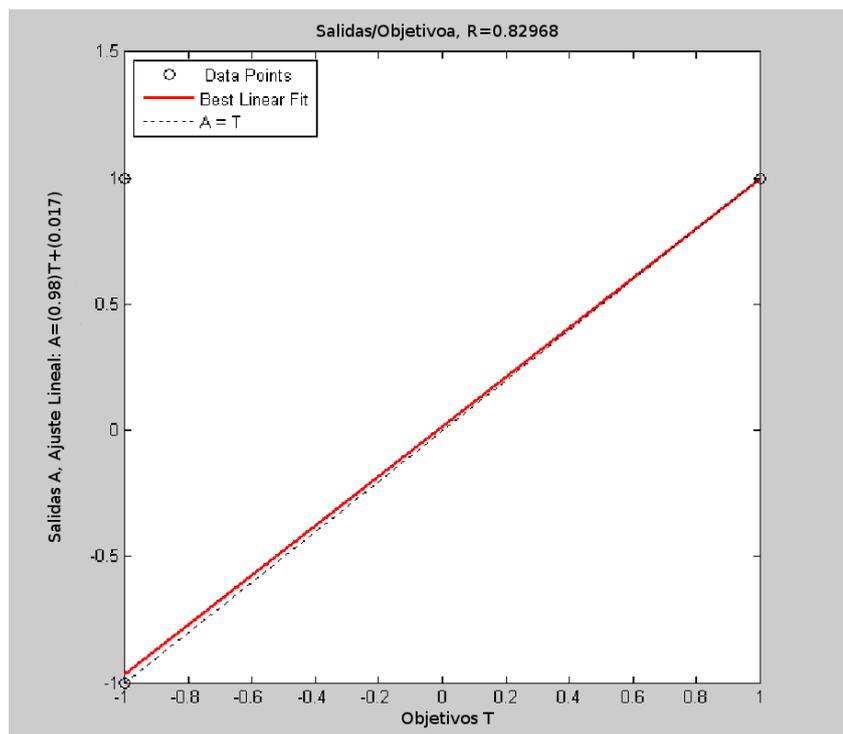


(a) Porosidad



(b) Grieta transversal

Figura 4.61: Análisis de regresión de la efectividad de un ANFIS con vector de entrada formado por las siguientes características: elongación, rectangularidad, excentricidad y *solidity*.



(a) Grieta longitudinal

Figura 4.62: Análisis de regresión de la efectividad de un ANFIS con vector de entrada formado por las siguientes características: elongación, rectangularidad, excentricidad y *solidity*.



# Capítulo Cinco

---

## Resultados y Discusión

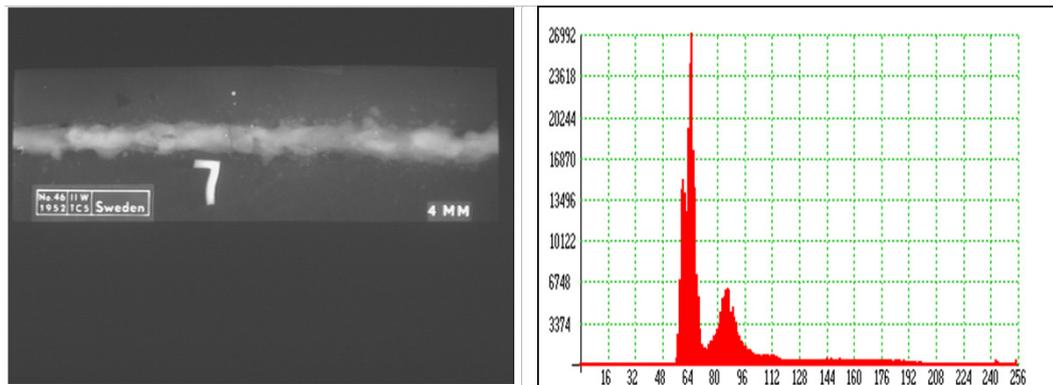
---

Una vez descrito y desarrollado en el capítulo anterior el conjunto de etapas que conforman el sistema propuesto para la detección automática de defectos en imágenes radiográficas de uniones soldadas, se realiza en este capítulo una valoración global del sistema y se presentan y discuten todos los resultados obtenidos por cada una de las técnicas empleadas en la implementación de cada una de las etapas, resaltando los aspectos más importantes.

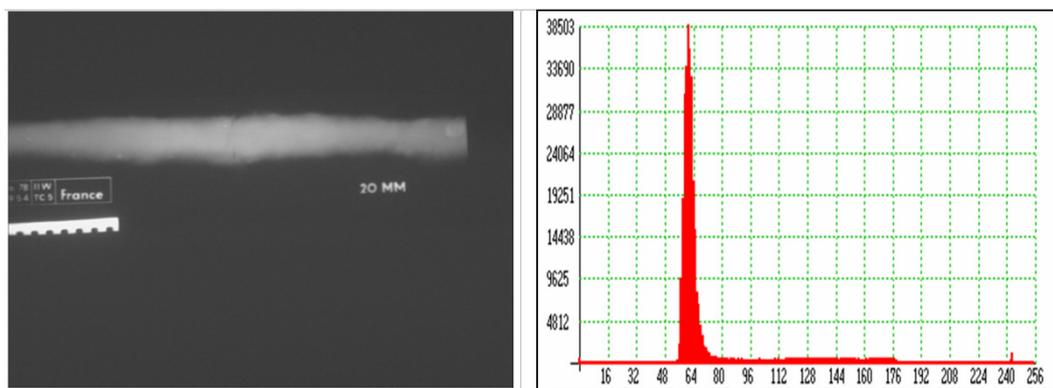
Para poner a prueba la fiabilidad de las metodologías propuestas se utilizaron un conjunto de 86 radiografías de uniones soldadas seleccionadas de entre los patrones del Instituto Internacional de Soldadura II/IIS. Dichas radiografías fueron elegidas, bien porque contenían uno o varios de los tipos de defectos (inclusiones de escoria, poros, grietas longitudinales y grietas transversales) que nos proponemos clasificar, o bien porque eran ejemplos de radiografías libres de defectos, por lo que se consideró que formaban un conjunto de test adecuado para la evaluación del sistema.

Una vez digitalizadas las radiografías seleccionadas, las imágenes obtenidas fueron analizadas y finalmente clasificadas por cuatro experimentados inspectores utilizando tres esquemas distintos de calificación. En primer lugar, se clasificaron basándose en la apariencia radiográfica en tres categorías: radiografías de complejidad baja, media y alta. En un segundo esquema, se utilizaron dos medidas cuantitativas para caracterizar las imágenes; utilizando como medida el contraste medio de la imagen completa, se ordenaron en tres grupos: radiografías de bajo, medio y alto contraste. Por último, atendiendo a la apariencia de los histogramas de los niveles de gris de la imagen, se clasificaron como imágenes con histogramas de modos solapados o sin solapar. Algunos ejemplos de imágenes calificadas que formaron parte del conjunto de test, junto con sus correspondientes histogramas, se muestran en la figura 5.1.

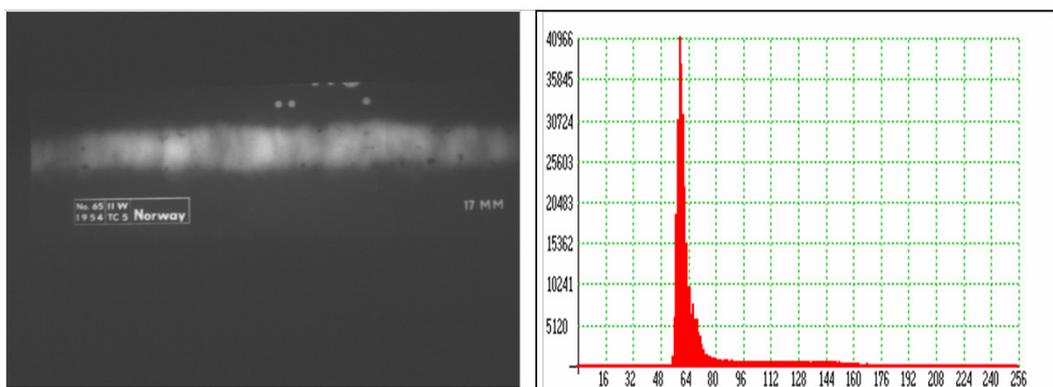
De acuerdo a la calificación realizada por los expertos, fueron clasificadas como de complejidad baja las imágenes (a) y (b), como de complejidad media las imágenes (c), (e), (f) y (h), y de complejidad alta las imágenes (d), (g) y (i). Atendiendo al parámetro contraste fueron clasificadas las imágenes (a), (b), y (f) como de alto contraste, las imágenes (c), (e), y (h) como de contraste medio y las imágenes (d), (g) y (i) dentro del grupo de bajo contraste. Por último, considerando el aspecto del histograma de cada radiografía, dentro de las nueve imágenes mostradas como ejemplo del conjunto de test se dan todas las situaciones posibles. Así, el histograma de la radiografía (a) está caracterizado por la existencia de dos modos no solapados;



(a)

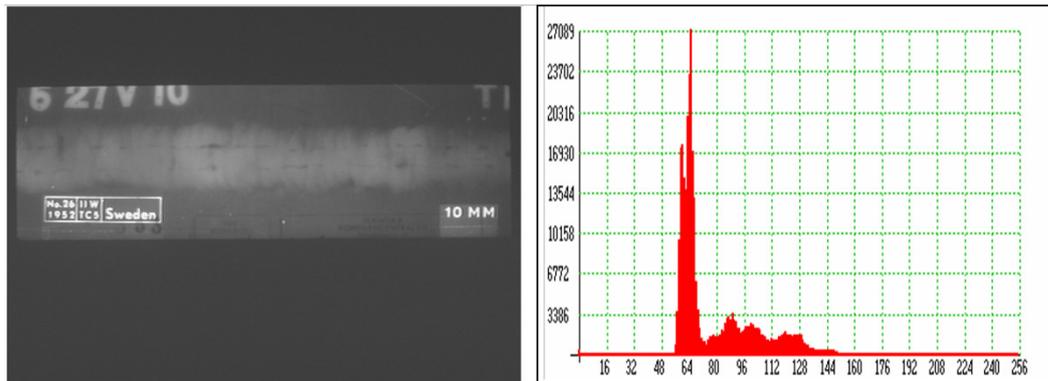


(b)

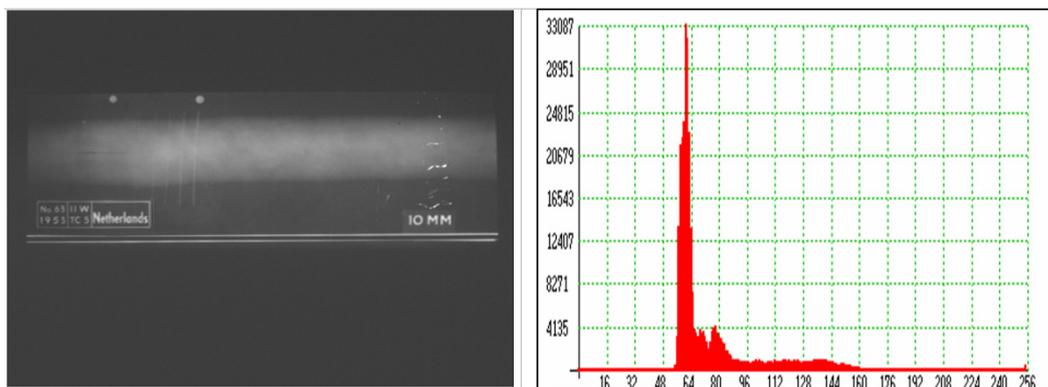


(c)

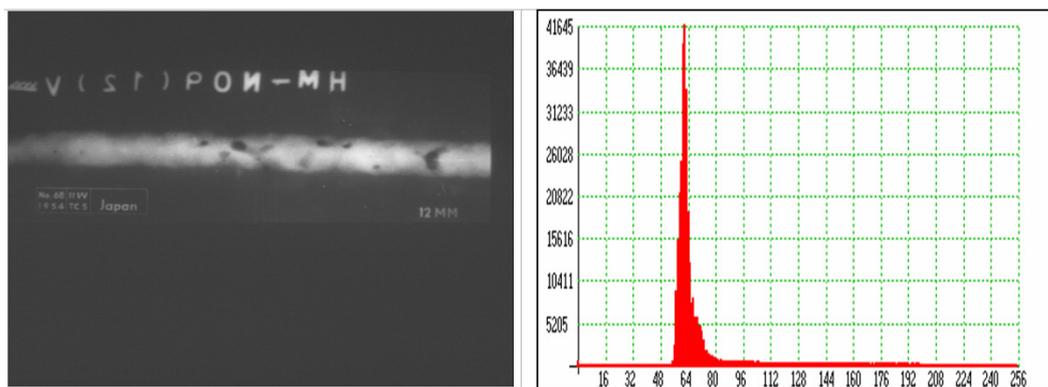
Figura 5.1: Ejemplos de imágenes del conjunto calificadas por los expertos.



(d)

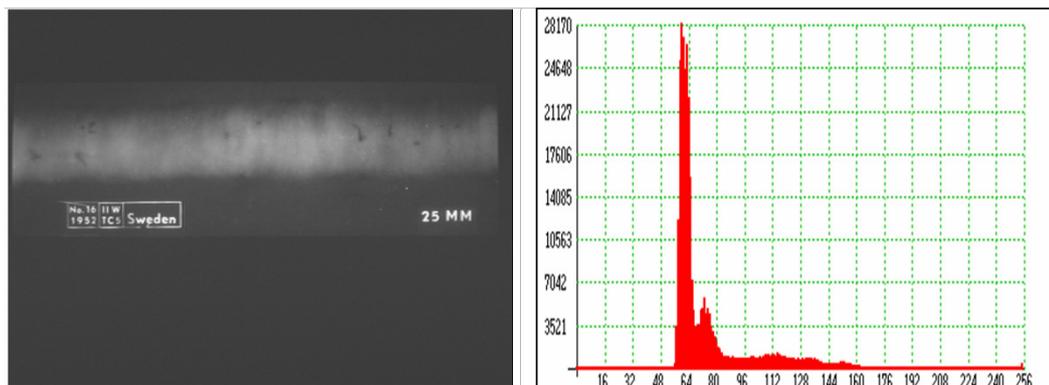


(e)

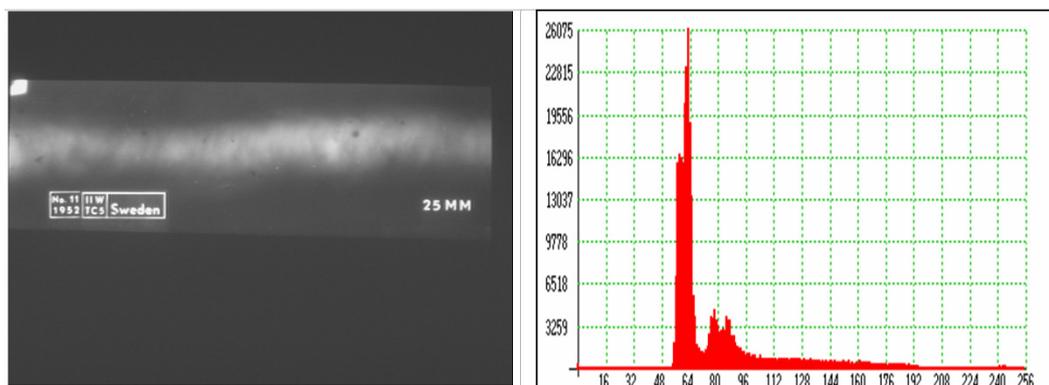


(f)

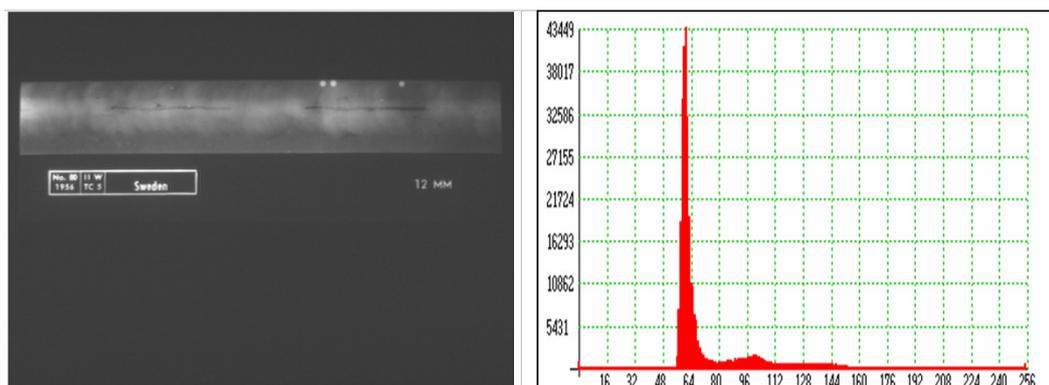
Figura 5.1: (Continuación).



(g)



(h)



(i)

Figura 5.1: (Continuación).

las imágenes de las figuras (e), (g) y (h) presentan un histograma en el que aparece un pico claramente diferenciado correspondiente al soporte radiográfico, luego existe un segundo pico, a lo sumo dos, correspondiéndose con la zona perteneciente al cordón de soldadura; finalmente las imágenes de las figuras (d) y (i) se caracterizan por presentar un histograma en el que aparece un pico claramente destacado, que se corresponde con el soporte radiográfico, seguido de varios picos que presentan solapamiento; este solapamiento es lo que provoca que la zona del cordón de soldadura aparezca con bajo contraste, lo que dificulta la acción de los algoritmos de segmentación.

Desde nuestro punto de vista, resulta cuestionable comparar las técnicas propuestas en este trabajo con las propuestas por otros autores en la bibliografía tanto para segmentar el cordón de soldadura, segmentar los defectos o clasificarlos, dado que no existe una base de radiografías genérica sobre la cual poner a competir todos los algoritmos en igualdad de condiciones. No obstante, sí es posible evaluar la eficiencia de cada una de las soluciones propuestas en esta memoria para cada etapa del sistema utilizando el conjunto de radiografías calificadas.

A continuación describimos los resultados obtenidos de cada etapa del sistema general, cuyo esquema fue descrito en el Preámbulo de esta memoria y cuya figura 1 nos proporciona una visión global de todo el sistema.

## 5.1 Segmentación de Cordones de Soldadura

Tal y como se describió en el capítulo 4 de esta memoria, hemos diseñado e implementado tres propuestas para la segmentación automática del cordón de soldadura. La primera propuesta a la que denominamos *técnica de segmentación basada en perfiles* se basa en el intento de superar los inconvenientes observados en la utilización de técnicas de umbralización con la inyección de conocimiento previo del dominio. La segunda propuesta se le ha denominado *técnica de segmentación progresiva* y, al igual que la anterior recurre a la información proporcionada por la radiografía para llevar a cabo su análisis. Básicamente, esta técnica realiza sucesivas segmentaciones sobre la imagen, para tras una fase de eliminación de contornos aislar el cordón de soldadura. La última de las propuestas, que hemos denominado *técnica de segmentación basada en etiquetado de componentes conectados*, utiliza técnicas de umbralización óptima y etiquetado de regiones para finalmente a través de un criterio de selección, establecer aquella región que constituye el cordón de soldadura.

Para validar las tres soluciones propuestas para la segmentación automática del cordón de soldadura se utilizó como elemento de comparación el área del cordón de soldadura identificado manualmente por los inspectores sobre las 86 imágenes de uniones soldadas del conjunto de test y al que llamaremos en adelante cordón real.

Definimos como *Semejanza* al porcentaje de coincidencia entre el área detectada automáticamente por el sistema mediante las diferentes técnicas propuestas y el cordón real, que se puede calcular como:

$$\text{Semejanza}(\%) = \frac{\text{concordancia área}}{\text{área real}} \times 100 \quad (5.1)$$

Los valores obtenidos de semejanza por cada una de las soluciones propuestas, en cada una de las categorías de imágenes radiográficas, así como la semejanza me-

dia para todas las categorías se muestran en la tabla 5.1. Los resultados indican que las tres propuestas formuladas para resolver la etapa de segmentación del cordón alcanzan valores de semejanza medios por encima del 85 %. El método de segmentación basado en perfiles obtuvo un 85 %, el de segmentación progresiva un 87 % y por último de segmentación por etiquetado de componentes conectados un 89 %. En el grupo de imágenes calificadas como de bajo contraste las tres técnicas obtuvieron valores de *semejanza* por debajo del 85 %, aunque sin bajar en ningún caso del 80 %.

En las figuras 5.2 y 5.3 se muestran, a modo de ejemplo, algunas imágenes resultado de la aplicación del método de segmentación de cordones de soldadura por etiquetado de componentes conectados, por ser este el método que mejores resultados obtuvo.

## 5.2 Segmentación de Heterogeneidades Candidatas a Defectos

Para resolver esta etapa del sistema general proponemos un procedimiento análogo al último de los propuestos en la etapa anterior de segmentación del cordón de soldadura, que describimos de forma detallada en el capítulo anterior y que denominamos segmentación por etiquetado de componentes conectados.

Para validar el procedimiento propuesto se utilizó el mismo conjunto de 86 imágenes radiográficas de la colección de referencia del IIW/IIS. En esta ocasión se pidió a los inspectores que realizaran la inspección de cada imagen, sin comentar sus impresiones con los otros inspectores, y que completaran un pequeño informe incluyendo sus conclusiones, los defectos detectados y sus localizaciones. El mismo conjunto de imágenes fue evaluado por el sistema.

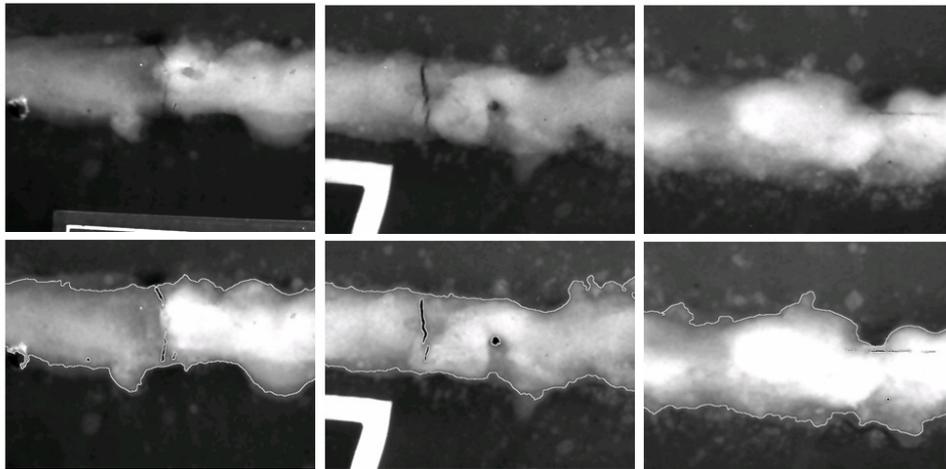
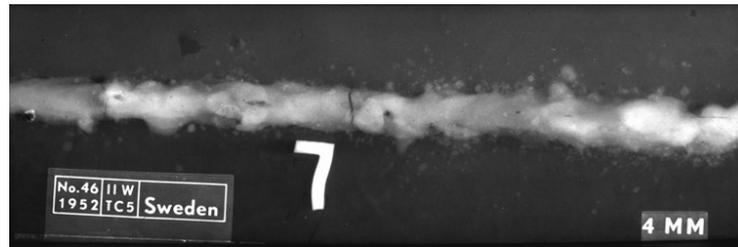
En el conjunto de regiones segmentadas por el sistema, es decir, heterogeneidades candidatas a defectos, debemos distinguir distintos tipos de regiones: aquellas que llamamos *verdaderos positivos* (VP) que la forman las regiones detectadas por el sistema y que fueron consideradas como defectos por los inspectores; las denominadas *falsos positivos* (FP) y que serían aquellas regiones segmentadas por el sistema y no fueron consideradas como defectos por los inspectores; y por último las que denominamos *falsos negativos* (FN) y que corresponden a aquellas regiones que el sistema no fue capaz de detectar y que sin embargo fueron consideradas como defectos por los inspectores.

Para evaluar el rendimiento del sistema, se utilizó la propiedad denominada *Sensibilidad* que se define de la siguiente forma:

$$\text{Sensibilidad}(\%) = \frac{\text{VP}}{\text{VP} + \text{FN}} \times 100 \quad (5.2)$$

Es importante saber si el sistema es capaz de detectar todos los defectos. En esta etapa, nuestro sistema fue capaz de obtener una sensibilidad del 100 %. Es decir, el sistema detectó como candidatos a defectos todos los observados por los expertos humanos. Para un sistema de detección de defectos es muy importante tener una mínima pérdida de regiones defectos, aun a costa de incrementar el número de objetos no-defectos.

IIW/IIS  
Commission V  
Nº. 46  
Type of  
Discontinuity:  
Cracks Long. Trans.



IIW/IIS  
Commission V  
Nº. 11  
Type of Discontinuity:  
Slag inclusions of any  
shape, in any direction

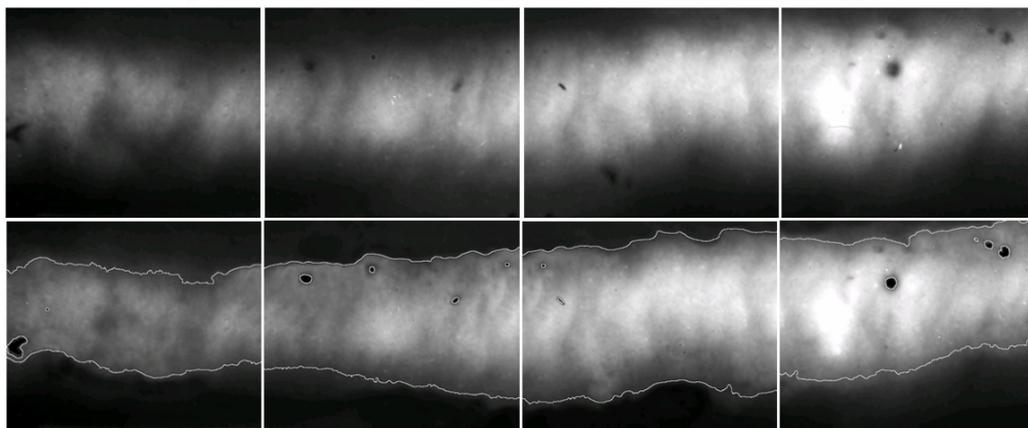
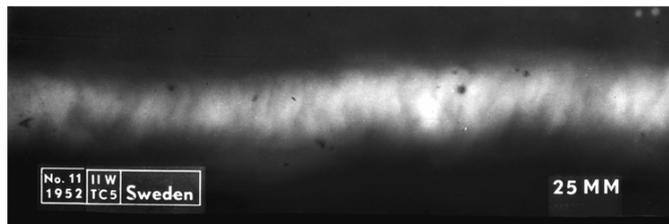


Figura 5.2: Ejemplos de resultados de la etapa de segmentación de cordón utilizando el método de etiquetado de componentes conectados.

## 5. RESULTADOS Y DISCUSIÓN

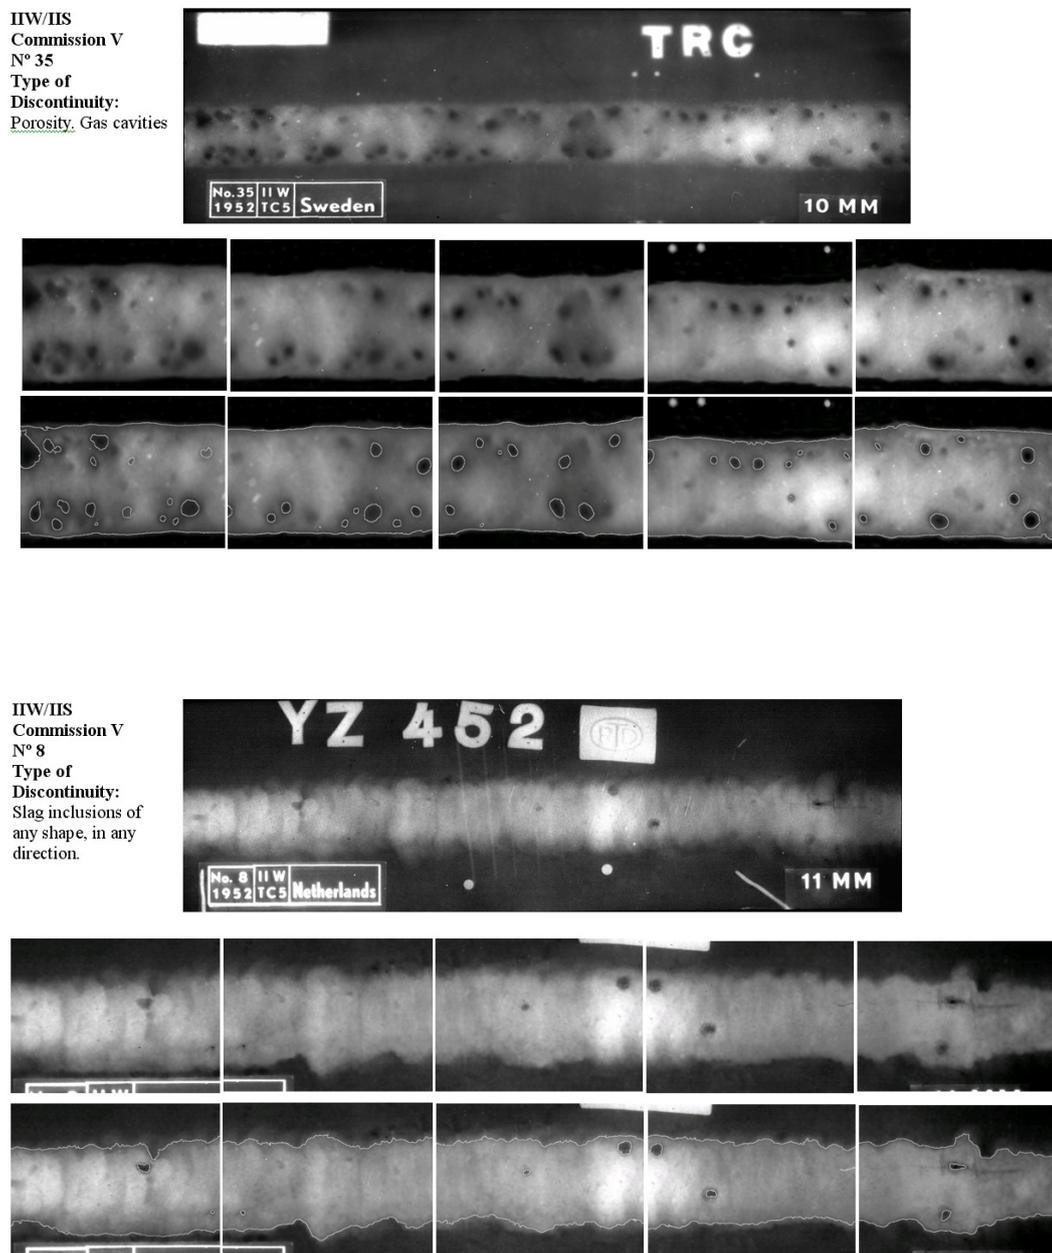


Figura 5.3: Ejemplos de resultados de la etapa de segmentación de cordón utilizando el método de etiquetado de componentes conectados.

Categoría	Semejanza (%)		
	Perfiles	Progresiva	Etiquetado
<i>Aspecto radiográfico</i>			
Baja Complejidad	89	90	91
Media Complejidad	85	87	88
Alta Complejidad	82	84	85
<i>Contraste</i>			
Bajo Contraste	80	81	83
Medio Contraste	84	86	88
Alto Contraste	89	93	95
<i>Histograma</i>			
Histograma solapado	84	89	91
Histograma no solapado	85	92	94
<i>Semejanza media</i>	85	87	89

Tabla 5.1: Rendimiento de los métodos propuestos para la segmentación del cordón de soldadura.

Conviene subrayar el bajo número de falsos positivos FP obtenidos, lo que, de cara a asegurar la eficacia de las siguientes etapas del sistema, donde se deben confirmar los candidatos como defectos para su clasificación, es muy importante desde el punto de vista de coste computacional.

En la figura 5.4 se muestran los resultados de la aplicación del método propuesto sobre algunas ejemplos de imágenes radiográficas.

En el apéndice A de esta memoria se incluyen los resultados de las etapas de segmentación del cordón de soldadura y de segmentación de heterogeneidades candidatas a defecto obtenidos sobre 30 imágenes digitalizadas de radiografías de uniones soldadas conteniendo defectos.

### 5.3 Clasificación Mediante Red Neuronal Artificial Multicapa Retro-alimentada (ANN)

Una vez segmentadas las heterogeneidades candidatas a defectos, extraídas sus características y seleccionadas las más relevantes, procede abordar la última etapa del sistema automático de inspección de imágenes radiográficas de uniones soldadas. En esta última fase, se han de clasificar y catalogar los diferentes candidatos.

Para acometer esta tarea, se proponen dos enfoques distintos que se sitúan en el campo de los sistemas neuroborrosos, campo que viene recibiendo gran atención por parte de los investigadores en estos últimos años. La primera propuesta se sitúa de lleno en el ámbito de las redes neuronales artificiales, al emplearse un perceptrón multicapa como clasificador de defectos, y la segunda se desplaza hacia los sistemas híbridos neuroborrosos, empleando una arquitectura ANFIS para el clasificador.

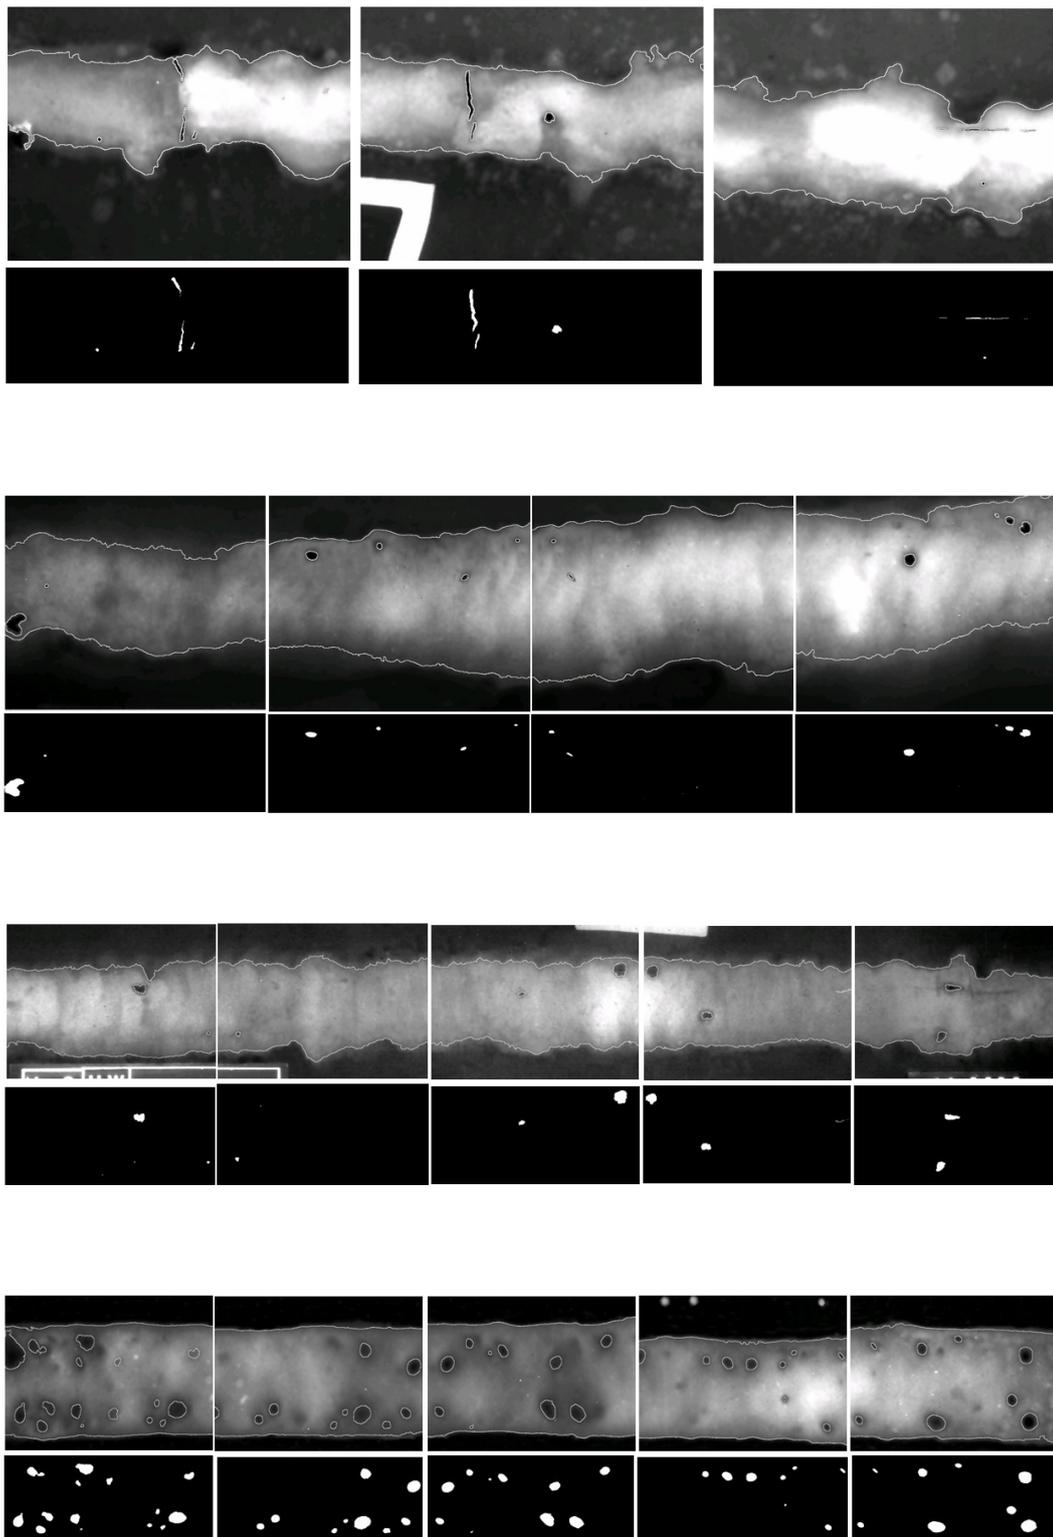


Figura 5.4: Ejemplos de resultados de la etapa de segmentación de heterogeneidades candidatas a defecto utilizando el método de etiquetado de componentes conectados.

En esta sección nos referiremos específicamente a los resultados de clasificación obtenidos mediante el primer enfoque.

El estudio del rendimiento de la etapa de clasificación de defectos mediante ANN se realizó por medio de un análisis de regresión entre la respuesta de la red y los correspondientes objetivos, de forma que se estudiaron las diferentes respuestas de la red al variar el número de neuronas  $R$  en la capa de entrada (mediante análisis de componentes principales), el número  $S^1$  de neuronas en la capa oculta, y observando el rendimiento del clasificador para cada defecto y para cada método de mejora de la generalización. De este modo fue posible obtener el número más adecuado de neuronas para la capa de entrada y para la capa oculta, así como el método de mejora de la generalización más apropiado.

La figura 5.5 muestra las gráficas de los coeficientes de correlación obtenidos para cada clase de defecto de la ANN en función del número de neuronas  $R$  en la capa de entrada, el número  $S^1$  de neuronas en la capa oculta y en donde no se utilizó ningún método de mejora de la generalización.

Las figuras 5.6, 5.7 y 5.8 ilustran las gráficas de los coeficientes de correlación proporcionados por análisis de regresión para los métodos de mejora de la generalización mediante función de rendimiento modificada, regularización Bayesiana y *stopping early*, para cada clase de defecto.

En la figura 5.9 se ilustra, como resumen, las medias de los coeficientes de correlación obtenidos para todos los tipos de defectos obtenidos por la ANN en función del número de neuronas  $R$  en la capa de entrada, el número  $S^1$  de neuronas en la capa oculta y para los tres métodos de mejora de la generalización y sin procedimiento de mejora.

Del análisis de los resultados podemos concluir que, en general, todas las salidas parecen seguir los objetivos razonablemente bien y todos los coeficientes de correlación están alrededor de 0.8. En algún caso particular, como el de la grieta transversal con regularización Bayesiana y *stopping early*, y números reducidos de las características de entrada el coeficiente de correlación no fue tan bueno. Este valor relativamente bajo es debido al escaso número de ejemplos de grietas transversales incluidos en el conjunto de imágenes radiográficas del IIW que fueron utilizadas para entrenar a la red.

Los resultados reflejados en las anteriores figuras se resumen, para una mejor interpretación, en la tabla 5.2, donde se muestran los valores más altos de coeficientes de correlación (C.C.) obtenidos variando el número de neuronas en la capa de entrada y en la capa oculta, para cada clase de defecto, y utilizando cada uno de los métodos de mejora de la generalización y sin emplear ningún método. En la tabla 5.2 aparecen subrayados los resultados óptimos para nuestro objetivo.

Los resultados indican que la mejor implementación es una red neuronal con PCA con una conservación de 99.9%, que se consigue con 11 neuronas en la capa de entrada, una capa oculta con 20 neuronas con función de transferencia sigmoideal de tangente hiperbólica, y una capa de salida con función de transferencia lineal.

## 5. RESULTADOS Y DISCUSIÓN

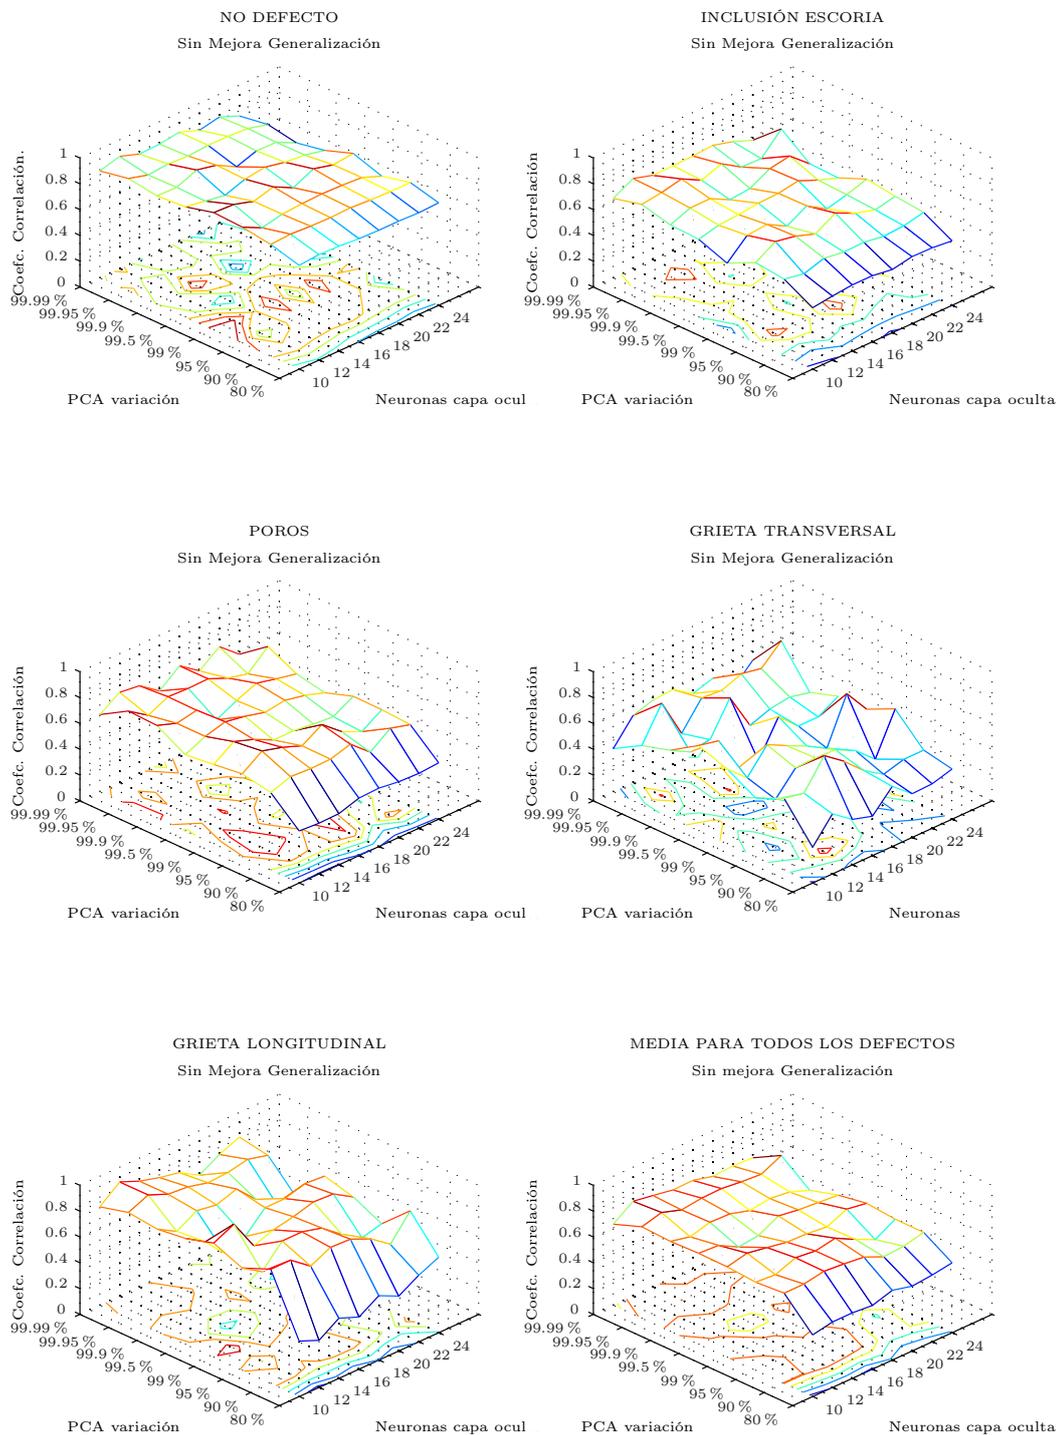


Figura 5.5: Coeficiente de correlación para cada clase de defecto sin mejora de la generalización.

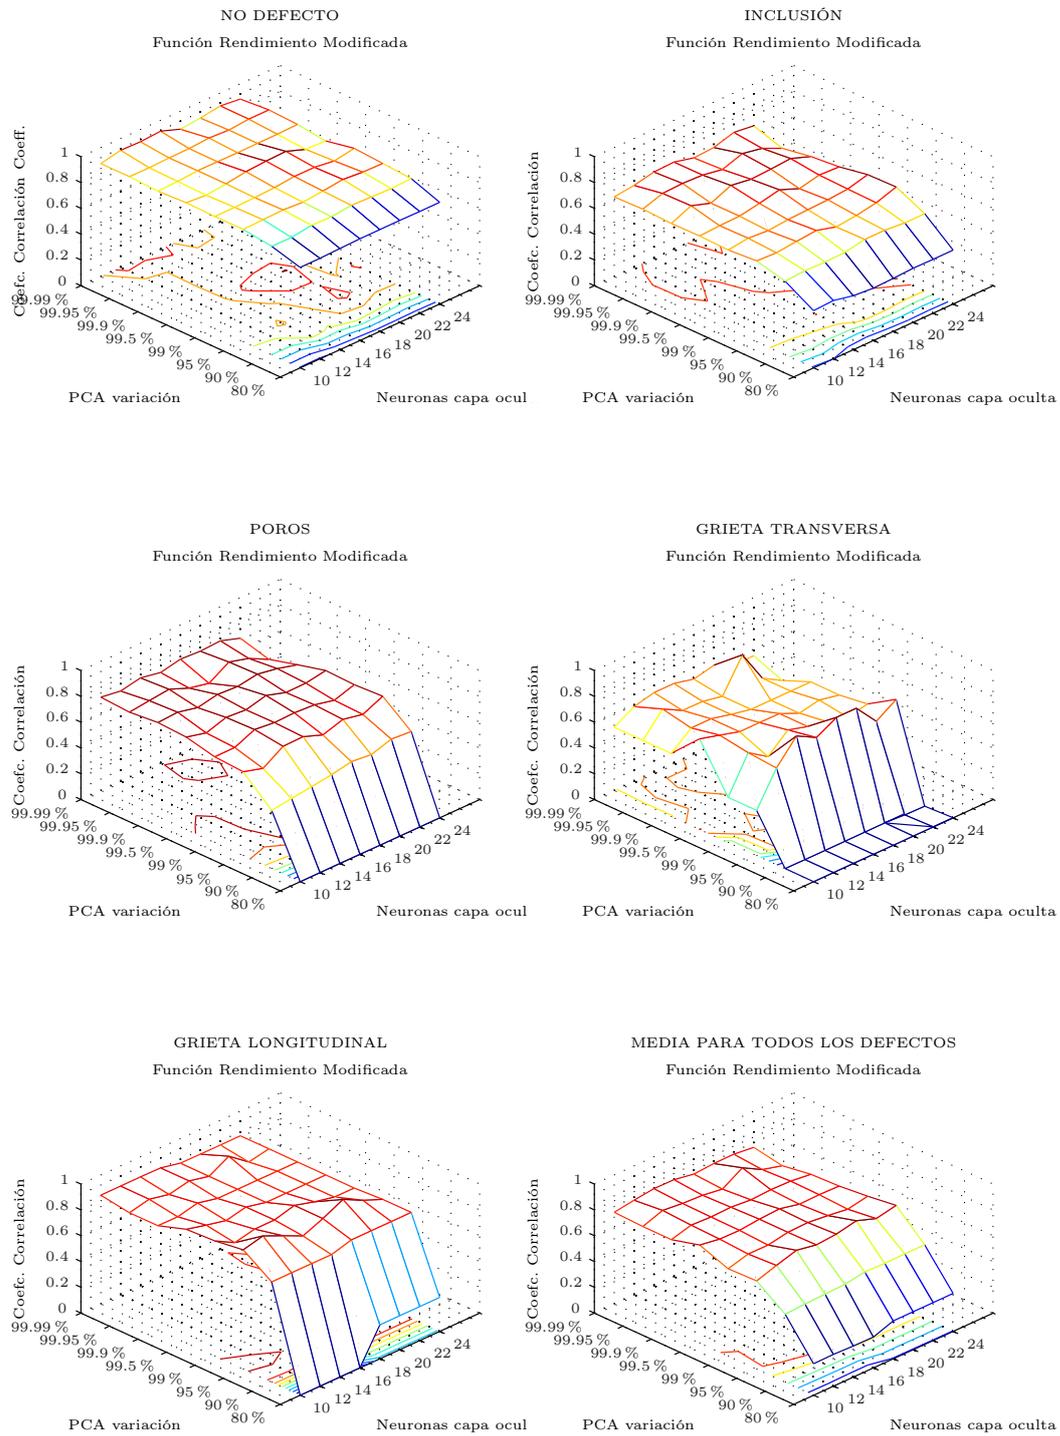


Figura 5.6: Coeficiente de correlación para cada clase de defecto con mejora de la generalización mediante función de rendimiento modificada.

## 5. RESULTADOS Y DISCUSIÓN

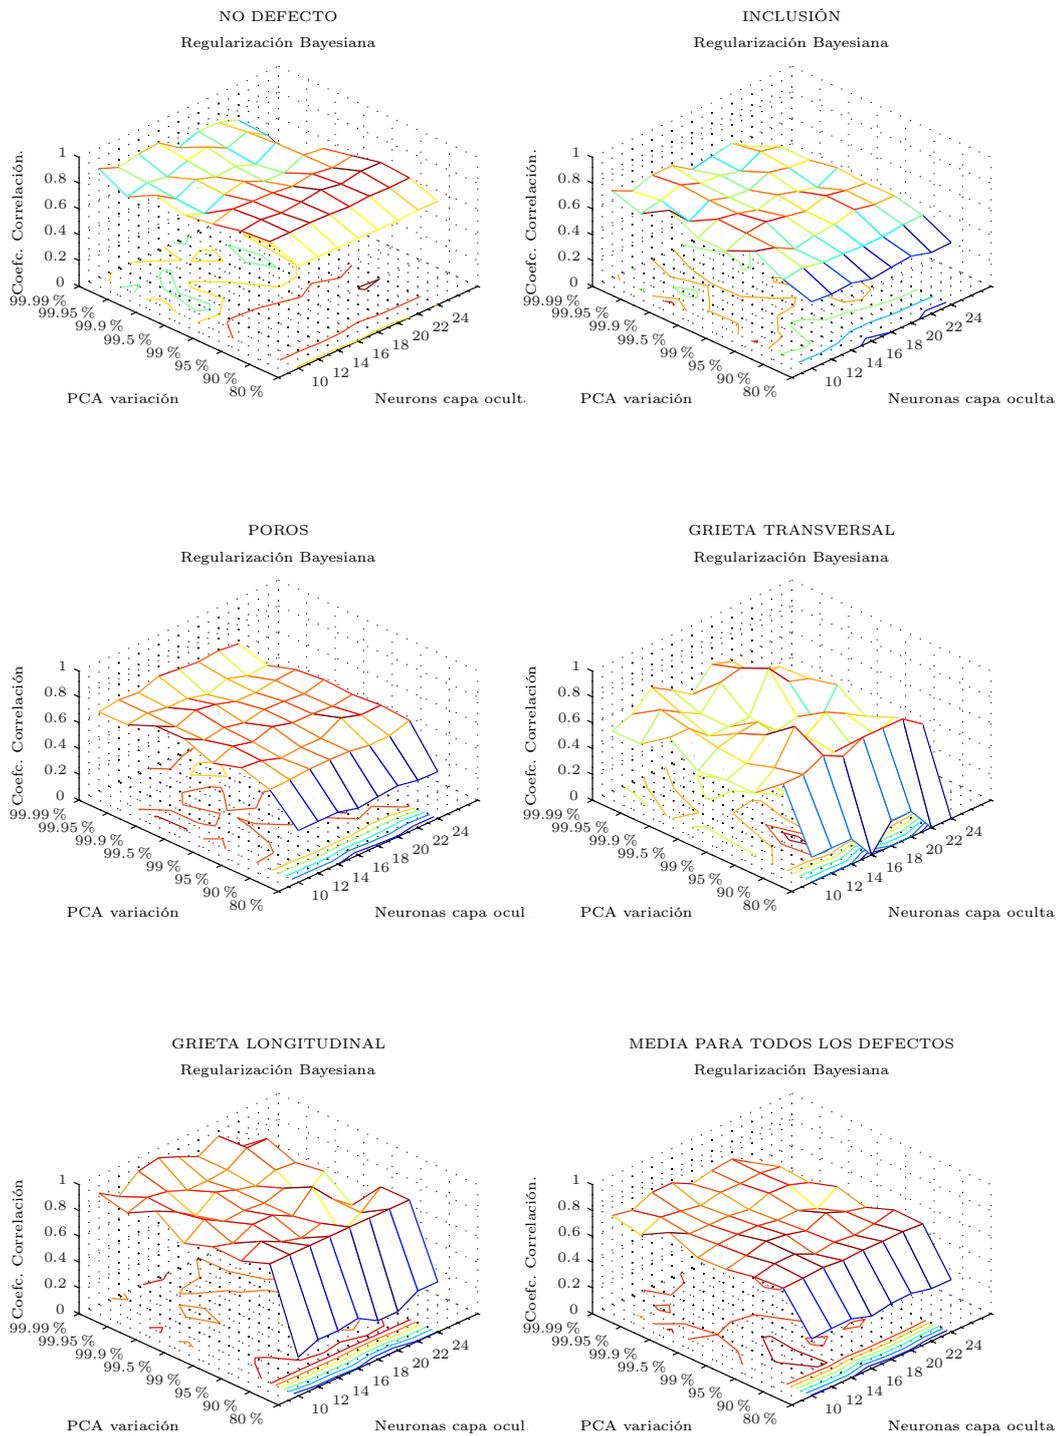


Figura 5.7: Coeficiente de correlación para cada clase de defecto con regularización Bayesiana.

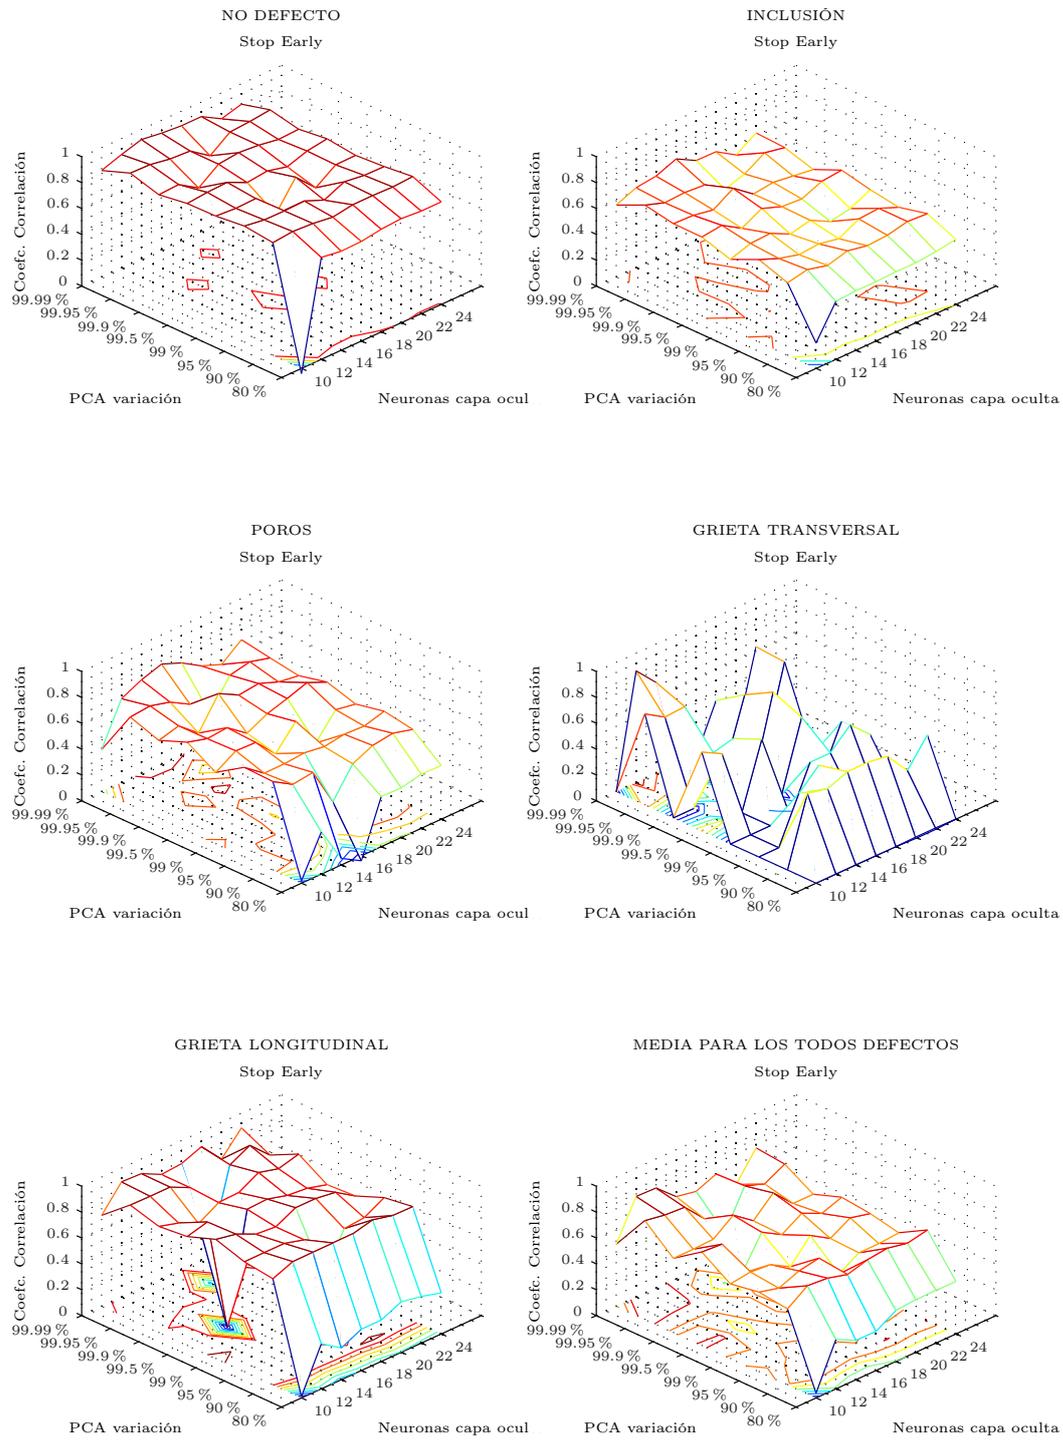


Figura 5.8: Coeficiente de correlación para cada clase de defecto con mejora de la generalización early stopping (bootstrap).

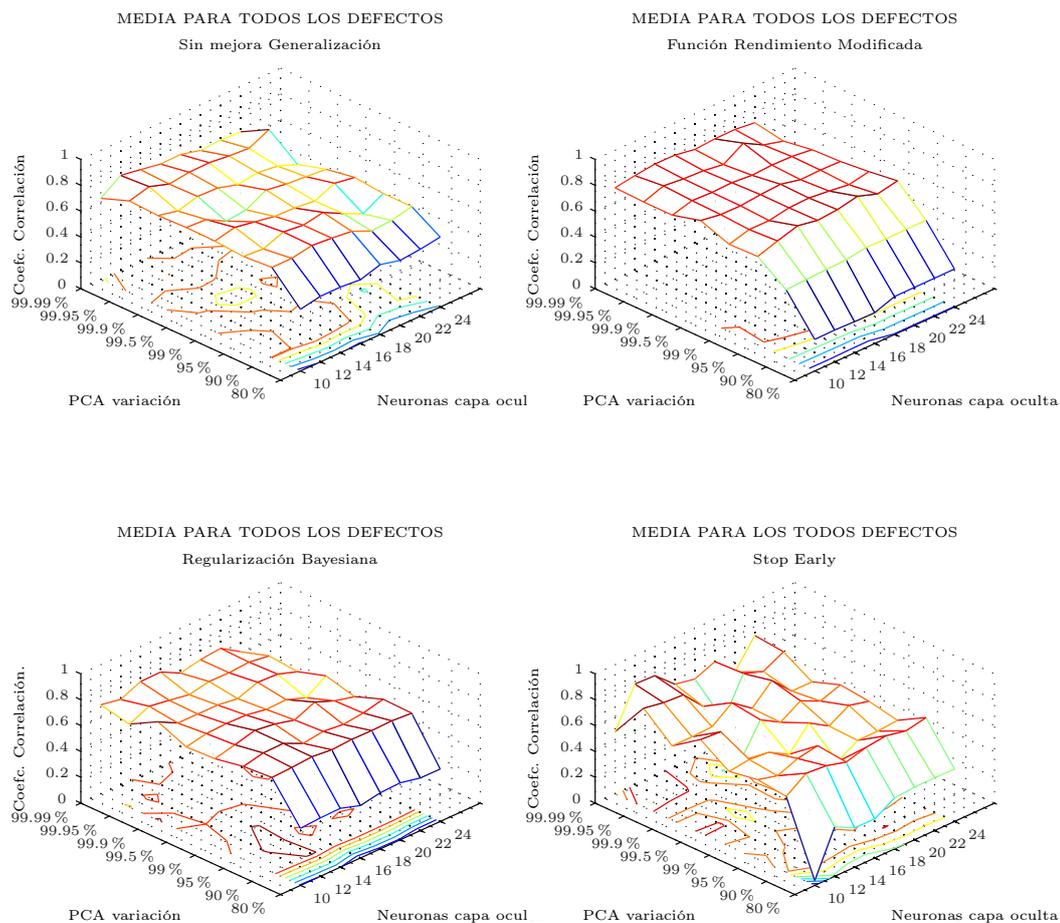


Figura 5.9: Coeficiente de correlación medio para todos los tipos de defectos.

El método de mejora de la generalización se basó en una función de rendimiento modificada con razón de rendimiento fija  $\gamma = 0.5$ . El algoritmo de entrenamiento fue cuasi-Newton para optimización rápida, siguiendo una implementación BFGS.

En la tabla 5.3 se muestran (subrayados) algunos valores del coeficiente de correlación obtenidos por la ANN con mejores resultados promedio. La ANN con el método de mejora de la generalización basado en la función de rendimiento modificada ha obtenido los mejores resultados para tres clases de defectos. Por eso, esta ANN supervisada fue la elegida para clasificar los defectos de soldadura.

El problema de la utilización del método de mejora de la generalización mediante regularización basada en la función de rendimiento modificada estriba en la dificultad de determinar el valor óptimo para el parámetro de razón de rendimiento ( $\gamma$ ). Si se hace este parámetro demasiado grande, se puede producir *overfitting*; por contra, si la razón es demasiado pequeña, no habrá un ajuste adecuado. En el estudio anterior a este parámetro se le adjudicó un valor fijo  $\gamma = 0.5$ .

		Métodos de Mejora de la Generalización											
		No Generaliz.			F. Rend. Mod.			Regres. Bayes.			Stop. early		
Tipos Defectos	No defecto	0.9210	8	10	0.9295	10	20	0.9402	7	22	0.9279	11	14
	Inclusiones	0.7137	11	24	0.7505	7	24	0.7309	11	10	0.7130	11	16
	Poros	0.7542	7	12	0.7652	10	18	0.7304	7	20	0.7804	11	16
	Grietas T.	0.7804	11	24	0.8078	11	22	0.8670	7	14	0.8736	11	12
	Grietas L.	0.9630	8	12	0.9643	2	22	0.9683	8	20	0.9303	8	10
	Media	0.7768	11	24	<u>0.8010</u>	<u>11</u>	<u>20</u>	0.7691	8	20	0.7852	11	12
		C.C.	R	$S^1$	C.C.	R	$S^1$	C.C.	R	$S^1$	C.C.	R	$S^1$

Tabla 5.2: Mejores resultados de coeficientes de correlación (C.C.) en función del número de neuronas en la capa de entrada (R) y en la capa oculta ( $S^1$ ), para cada clase de defecto y para cada método de mejora de la generalización.

		Métodos de Mejora de la Generalización			
		No Generaliz.	F. Rend. Mod.	Regres. Bayes.	Stop. early
		R=11, $S^1$ = 24	R= 11, $S^1$ = 20	R=8, $S^1$ = 20	R=11, $S^1$ = 12
Tipos Defectos	No defecto	0.7984	<u>0.8893</u>	0.8542	0.8769
	Inclusiones	0.7137	<u>0.7123</u>	0.6834	0.6202
	Poros	0.7361	<u>0.7473</u>	0.6509	0.6509
	Grietas T.	0.7804	0.7989	0.6641	<u>0.8736</u>
	Grietas L.	0.7705	0.8930	<u>0.9683</u>	0.8940
	Media	0.7768	<u>0.8081</u>	0.7691	0.7852

Tabla 5.3: Resultados para coeficientes de correlación (C.C.) para las ANN con mejor promedio para cada clase de defectos y para cada método de mejora de la generalización. La capa de entrada es (R) y en la capa oculta es ( $S^1$ ).

Con objeto de determinar el valor óptimo de la razón de rendimiento ( $\gamma$ ) se entrenó nuevamente la ANN con el mismo conjunto de patrones. En este caso, sin embargo, se utilizó para la mejora de la generalización también el parámetro de razón de rendimiento ( $\gamma$ ), que fue modificando su valor desde 0.1 a 1 con el objetivo de encontrar la topología óptima del red [100].

Las figuras 5.10 y 5.11 ilustran gráficamente la media de los coeficientes de correlación (para todas las clases de defectos) proporcionados por el análisis de regresión para cada valor de la razón de rendimiento ( $\gamma$ ) en el proceso de regularización.

Del análisis de los resultados podemos concluir que, en general, todas las salidas parecen seguir los objetivos de manera razonable para todos los valores de ( $\gamma$ ) en la función de rendimiento modificada, ya que todos las medias de los coeficientes están por encima de 0.8. Para alguna variación de PCA por debajo del 95 % esta media para el coeficiente de correlación no es tan buena.

Los resultados reflejados en las figuras anteriores se resumen para una mejor

interpretación en la tabla 5.4, donde se muestran los resultados de los coeficientes de correlación obtenidos variando el número de neuronas en la capa de entrada ( $R$ ) y en la capa oculta ( $S^1$ ) para cada clase de defecto y variando el valor de ( $\gamma$ ) entre 0.1 y 1. En la tabla aparecen subrayados los resultados óptimos para nuestro objetivo.

Los resultados resumidos en la tabla 5.4 apuntan a que la mejor implementación es una red neuronal con PCA con una conservación del 99.9% de los datos (11 neuronas en la capa de entrada), una capa oculta con 18 neuronas con función de transferencia sigmoideal de tangente hiperbólica, y una capa de salida con función de transferencia lineal. El método de mejora de la generalización se basó en una función de rendimiento modificado con razón de rendimiento fija  $\gamma = 0.6$ . El algoritmo de entrenamiento fue cuasi-Newton para optimización rápida según la implementación BFGS.

Cuando un conjunto de datos está desequilibrado porque el número de muestras en diferentes clases varían en gran medida, el coeficiente de correlación de un clasificador puede que no sea la forma más adecuada de evaluar el comportamiento real del clasificador. Con el fin de mostrar el verdadero rendimiento del método propuesto se utilizó una matriz de confusión. En la tabla 5.5 mostramos la matriz de confusión de nuestro clasificador basado en ANN, en la que podemos ver que el sistema no confunde ninguna clase; incluso la clase con menos muestras (grieta transversal) resulta perfectamente clasificada. La tabla de confusión también nos permite discernir el número de verdaderos negativos, falsos positivos, falsos negativos y positivos verdaderos. Los verdaderos positivos (VP) son los valores de la intersección de las filas y columnas representadas con la misma etiqueta (por ejemplo, para la clase no defecto es 120); los falsos positivos (FP) son el resto de los valores de esa fila (es decir, para la clase no defecto es  $10 + 5 + 0 + 1 = 16$ ); los falsos negativos (FN) son el resto de los valores de la columna (es decir, para la clase no defecto es  $8 + 8 + 1 + 3 = 20$ ); y finalmente los verdaderos negativos (VN) son el resto de los valores de la tabla de confusión (219 para la clase no defecto). La precisión (AC) es la proporción del número total de predicciones que eran correctas y se determina mediante la siguiente ecuación:

$$AC = \frac{VP + VN}{VP + FP + FN + VN} \quad (5.3)$$

Este valor se ha calculado para cada una de las categorías de clasificación y se muestra en la última columna de la tabla 5.5. A la vista de estos valores, las prestaciones del clasificador puede catalogarse de muy satisfactorias.

#### 5.4 Clasificación Mediante Sistema Adaptativo de Inferencia Neuro-Borrosa (ANFIS)

El segundo enfoque propuesto para clasificar los defectos, última etapa del sistema automático de inspección de uniones soldadas, propone que un vector tetradimensional formado con todas las combinaciones posibles de las 12 características extraídas de los candidatos a defectos en la etapa anterior del sistema sea la entrada a un sistema clasificador adaptativo de inferencia neuro-borrosa (ANFIS)

$\gamma$	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
$S^1$	12	12	12	12	20	18	12	12	14	20
R	11	11	11	10	11	11	11	10	8	7
Media	0.7995	0.8043	0.8010	0.8085	0.8081	<u>0.8127</u>	0.7911	0.7986	0.7868	0.7979
No defecto	0.9110	0.9165	0.9106	0.8896	0.8893	0.8675	0.8986	<u>0.9241</u>	0.8866	0.9073
Inclusión	0.6896	0.6766	0.6961	0.6544	0.7123	0.6677	0.6647	0.6360	<u>0.7281</u>	0.6862
Poros	0.7240	0.7492	0.7176	0.7487	0.7473	<u>0.7680</u>	0.7497	0.7194	0.7096	0.6801
Grieta T.	0.7876	0.7169	0.7879	0.7875	0.7989	0.8673	0.7169	0.7879	0.7169	<u>0.9349</u>
Grieta L.	0.8854	<u>0.9623</u>	0.8930	<u>0.9623</u>	0.8930	0.8930	0.9258	0.9258	0.8930	0.7883

Tabla 5.4: Coeficientes de Correlación (C.C.) para diferentes valores de  $\gamma$  y un número de neuronas en la capa de entrada (R) y capa oculta ( $S^1$ ) correspondientes a la media para cada clase de defecto

		Actual					Precisión
		No defecto	Inclusión.	Poros.	Grieta T.	Grieta L.	
Predicción	No defecto	120	10	5	0	1	0.90
	Inclusión.	8	90	14	2	0	0.84
	Poros.	8	22	67	0	0	0.86
	Grieta T.	1	2	1	6	0	0.98
	Grieta L.	3	2	0	0	13	0.98
Total		140	126	87	8	14	0.78

Tabla 5.5: Matriz de confusión para la obtención de la precisión de clasificación del sistema basado en ANN con regularización mediante función de rendimiento modificada. (R = 11,  $S^1 = 20$  ).

Un sistema de inferencia borrosa necesita seguir lo mejor posible al conjunto de datos entrada/salida. Debido a que el modelo de estructura que utiliza ANFIS es fijo, existe la tendencia a sobreajustar los datos sobre los que se está entrenando, especialmente cuando hay un gran número de iteraciones de entrenamiento. Si ocurre el sobreajuste, el sistema de inferencia borrosa podría no responder bien con otro conjunto de datos independientes, especialmente si estos están corrompidos por ruido. Generalmente, en estas situaciones se utiliza un conjunto de comprobación o validación. Este conjunto de datos se utiliza para la validación cruzada del modelo de inferencia borroso y necesita ser aplicada al conjunto de prueba del modelo para poder observar la bondad de la respuesta.

El rendimiento del sistema se midió realizando el análisis de regresión entre la respuesta y los correspondientes objetivos. El coeficiente de correlación obtenido entre las salidas y objetivos permitió estimar el ajuste entre las variaciones de salida y los objetivos. Si este número es igual a 1, entonces hay una perfecta correlación entre objetivos y salidas, lo que indica un ajuste perfecto.

Para proporcionar esta visión sobre el rendimiento del sistema de clasificación de defectos de soldadura propuesto, sobre el conjunto de datos de prueba se evaluó la eficacia de un ANFIS para clasificar las 5 clases de heterogeneidades utilizando

las 495 combinaciones posibles de las 12 características calculadas de los candidatos a defectos agrupadas de cuatro en cuatro. De esta forma, se pudo determinar las mejores cuatro características para clasificar las heterogeneidades.

En la tabla 5.6 se muestran los coeficientes de correlación para algunas de las combinaciones, donde los números representan cada una de las características: (1) aspecto, (2)  $e/A$ , (3)  $L/A$ , (4) índice de extensión, (5) redondez, (6) elongación, (7) rectangularidad, (8) diámetro equivalente, (9) orientación, (10) excentricidad, (11) número de Euler y (12) *solidity*. Las etiquetas que aparecen en la parte superior de la tabla identifican los tipos de defectos: *nd* no defecto, *si* inclusión de escoria, *po* porosidad, *tc* grieta transversal y *lc* grieta longitudinal. En la tabla aparecen subrayadas las mejores medias para las cinco clases de defectos.

En la figura 5.12 se muestran los coeficientes de correlación para cada combinación de entradas y para cada clase de defecto. Los mejores resultados se obtuvieron con un vector de entrada formado con los valores obtenidos para cada candidato a defecto de las siguientes características: *Excentricidad*, *Orientación*, *Rectangularidad* y *Solidity*. Con estas características se consiguieron las mejores medias en los coeficientes de correlación para las cinco clases: no defecto (0.87), inclusión de escoria (0.84), poros (0.87), grieta transversal (1) y grieta longitudinal (0.96).

Como en el caso del clasificador ANN y por idéntica razón de desequilibrio en el conjunto de los datos, vamos a intentar mostrar el verdadero rendimiento de este clasificador ANFIS construyendo su matriz de confusión y estimando los valores de precisión para cada categoría. La tabla 5.7 representa esta matriz, en la que podemos estimar los valores de VP, FP, FN y VN para cada una de las categorías siguiendo el mismo procedimiento que en el caso del clasificador ANN. Los valores resultantes de precisión por categorías presentados en la última columna de la tabla evidencian un comportamiento de este clasificador ANFIS aun mejor que el que obtuvimos con el clasificador ANN, en lo que a prestaciones promedio se refiere.

## 5.5 Discusión de los Resultados

Analizados los resultados obtenidos en cada una de las etapas críticas del sistema automático de inspección de imágenes radiográficas de uniones soldadas cabe extraer algunas conclusiones.

En lo que se refiere a la etapa de segmentación del cordón de soldadura, de los diferentes métodos ensayados el que mejores resultados ofreció, en términos del grado de coincidencia con el dictamen de los expertos, fue la técnica de segmentación por etiquetado de componentes conectados. Su rendimiento, medido en términos del índice de semejanza media, fue del 89%, lo que supone un valor excelente de concordancia con los expertos, teniendo en cuenta la dificultad de trazar el contorno del cordón en una mayoría de las imágenes reales.

La etapa de detección de heterogeneidades se sintonizó en cuanto a sus prestaciones para obtener una sensibilidad máxima (ausencia de falsos negativos), lo que se consiguió de forma plena al obtenerse un 100% en este índice. Esto nos asegura que en la etapa de clasificación entrarán todos los potenciales defectos que pudieran

Características				Coef. Correlación.				
				nd	si	po	tc	lc
1	6	10	11	0.87	0.80	0.87	0.95	0.96
1	9	10	11	0.93	0.69	0.69	0.79	0.91
1	6	10	12	0.89	0.75	0.78	1	0.91
1	9	10	12	0.91	0.71	0.74	1	1
1	7	10	11	0.89	0.80	0.79	0.95	0.97
1	7	10	12	0.89	0.72	0.73	1	0.91
1	7	9	11	0.81	0.77	0.76	0.88	0.82
1	6	7	9	0.87	0.82	0.89	0.71	0.69
6	7	10	12	0.90	0.77	0.81	0.95	0.96
<u>10</u>	<u>9</u>	<u>7</u>	<u>12</u>	<u>0.88</u>	<u>0.85</u>	<u>0.88</u>	<u>1</u>	<u>0.97</u>
7	9	10	11	0.89	0.87	0.84	0.94	0.93
6	9	10	11	0.89	0.81	0.86	1	0.96
6	7	11	12	0.88	0.84	0.86	0.94	0.86
7	10	11	12	0.91	0.78	0.82	0.94	0.94
2	3	4	5	0.89	0.82	0.78	0.82	0.89

Tabla 5.6: Algunos coeficientes de correlación obtenidos por ANFIS, para diferentes combinaciones de características.

		Actual					Precisión
		No defecto	Inclusión.	Poros.	Grieta T.	Grieta L.	
Predicción	No defecto	118	12	6	0	1	0.89
	Inclusión.	10	100	10	0	0	0.87
	Poros.	9	10	71	0	0	0.96
	Grieta T.	1	1	0	8	0	0.99
	Grieta L.	2	3	0	0	13	0.98
Total		140	126	87	8	14	0.82

Tabla 5.7: Matriz de confusión para la obtención de la precisión de clasificación de la arquitectura ANFIS.

encontrarse en el cordón de soldadura. En la etapa de clasificación de defectos se han ensayado de forma independiente dos propuestas, y ambas han proporcionado unos resultados satisfactorios.

La propuesta basada en la utilización de una red neuronal multicapa retroalimentada ha proporcionado los mejores resultados con la siguiente configuración:

- Capa de entrada con 11 neuronas, empleando la técnica PCA para la reducción de la dimensionalidad en el conjunto de características extraídas de los defectos.
- Capa oculta de 20 neuronas con función sigmoïdal de tangente hiperbólica

optimizada mediante análisis de regresión

- Capa de salida de 5 neuronas con función de transferencia lineal
- Algoritmo de cuasi-Newton (BFGS) como método de entrenamiento
- Mejora de la generalización mediante función de rendimiento modificada con ( $\gamma = 0.5$ )

Con esta configuración se alcanzó para este clasificador un rendimiento medio para las cinco clases de defectos, medido mediante los coeficientes de correlación con el dictamen experto, del 0.8.

Alternativamente, la propuesta de clasificador basada en una arquitectura neuroborrosa ANFIS supone, de entrada, una disminución considerable en el número de características de entrada al clasificador, lo que mitiga las exigencias computacionales de la etapa de extracción de características y reducción dimensional, en relación con el clasificador ANN. De un análisis previo de la combinación óptima de características para la clasificación con esta arquitectura, se obtuvo que las mejores prestaciones de este clasificador se obtenían con las características geométricas: *Excentricidad*, *Orientación*, *Diámetro equivalente* y *Solidity*. Las prestaciones obtenidas por este clasificador a partir de estas características, medidas en términos de los coeficientes de correlación con el dictamen experto, fueron en promedio del 0.91, sensiblemente superiores a las del clasificador ANN.

Para concluir, la figura 5.13 resume de forma gráfica las diferentes etapas de que consta el sistema completo de análisis automático de imágenes radiográficas de uniones soldadas, desarrollado en esta Tesis Doctoral. En dicha figura se presentan de forma separada las dos alternativas de clasificación que se han puesto a prueba en este trabajo, y que presentan arquitecturas y exigencias computacionales muy diferentes.

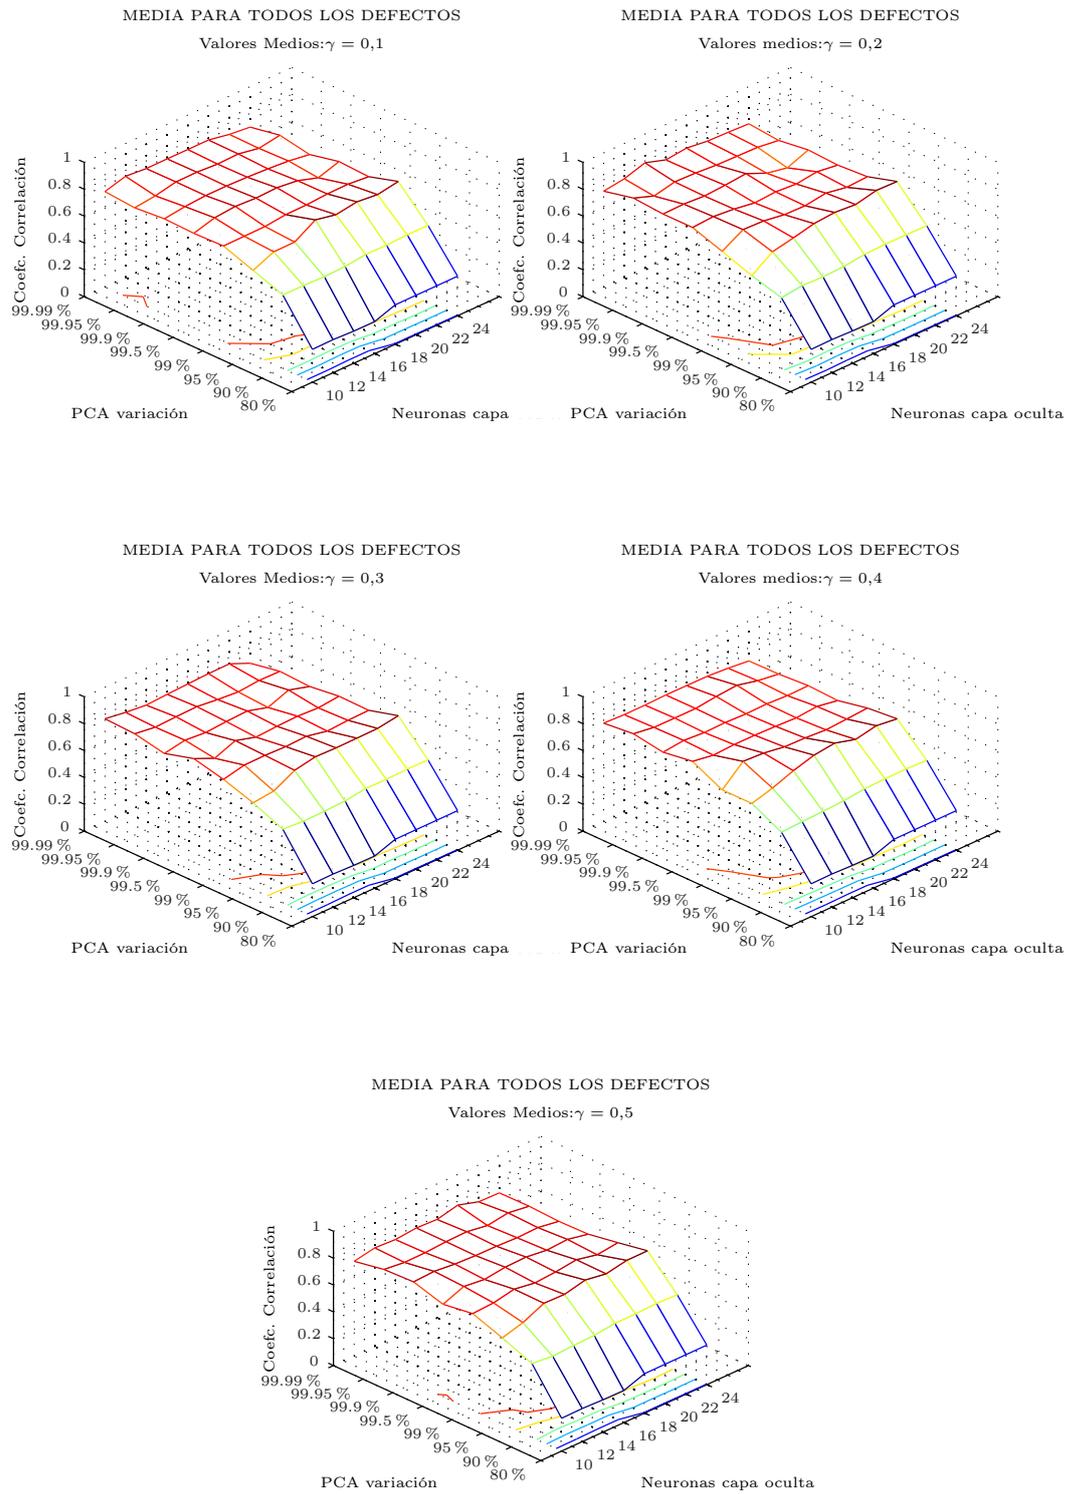


Figura 5.10: Media para todas las clases de defectos del coeficiente de correlación con diferentes ( $\gamma$ ) en la función de rendimiento modificada.

## 5. RESULTADOS Y DISCUSIÓN

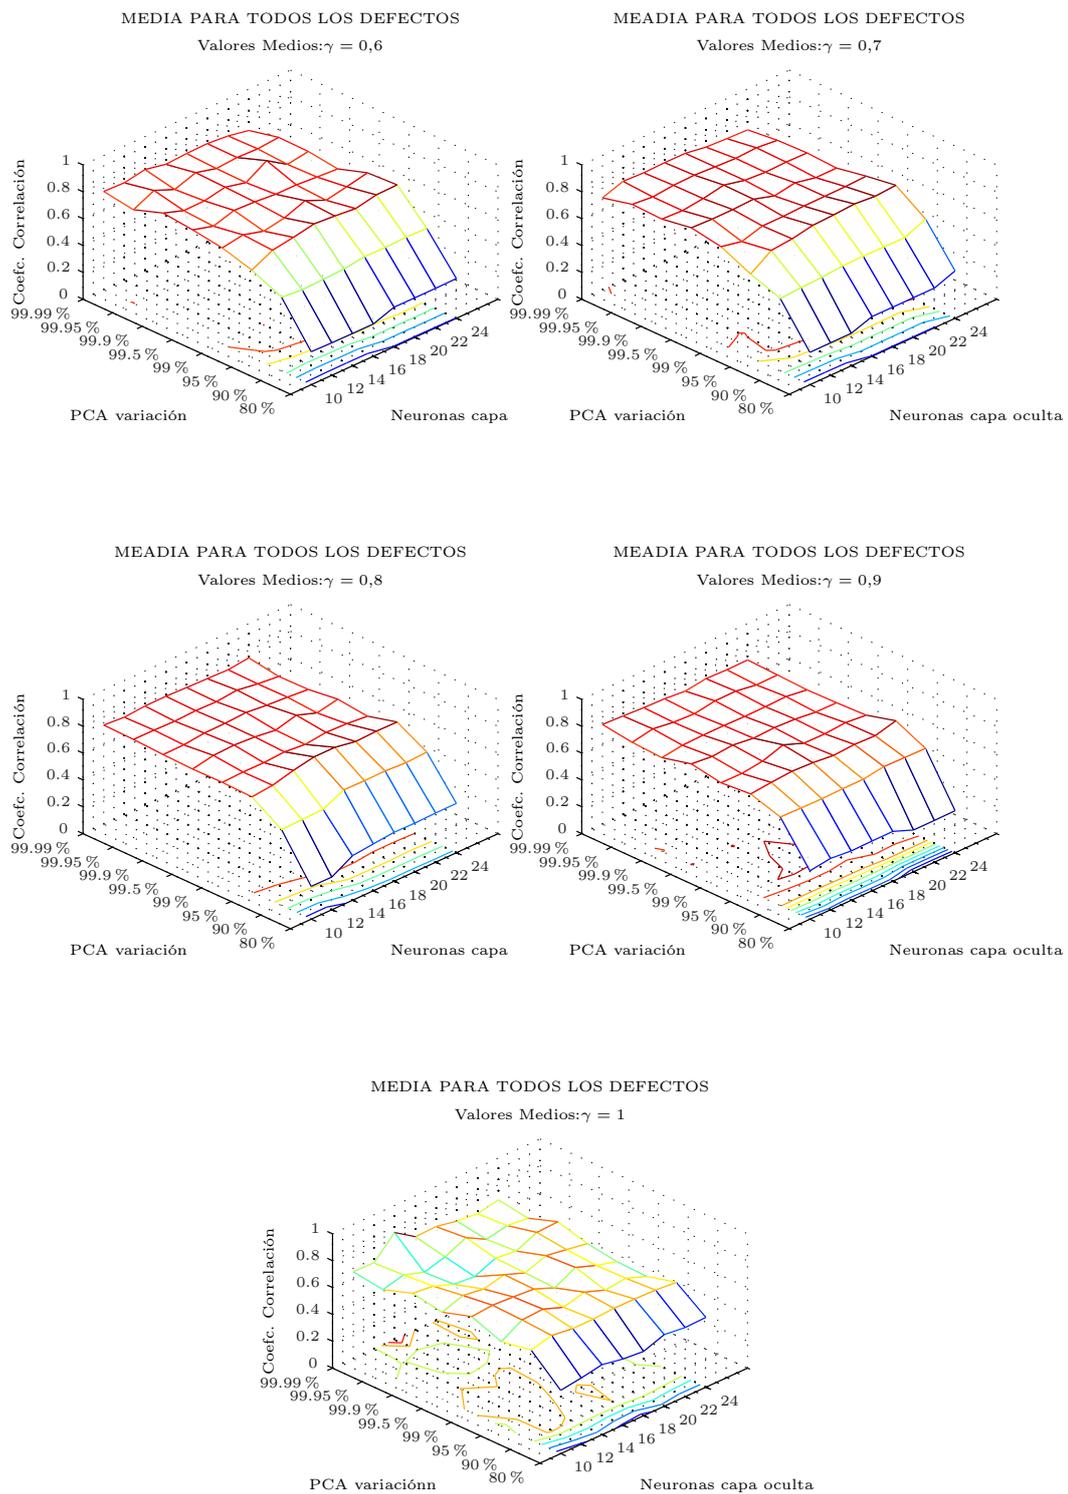


Figura 5.11: Media para todas las clases de defectos del coeficiente de correlación con diferentes ( $\gamma$ ) en la función de rendimiento modificada.

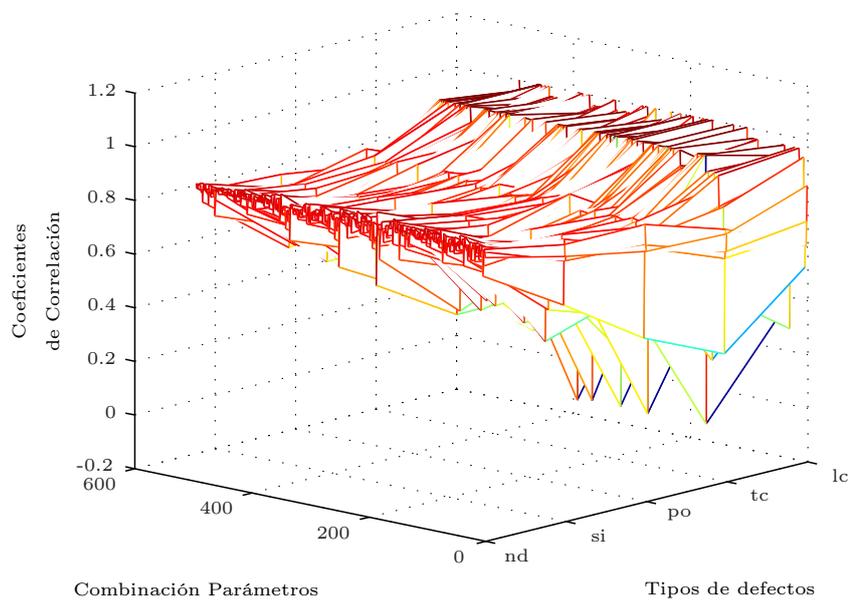
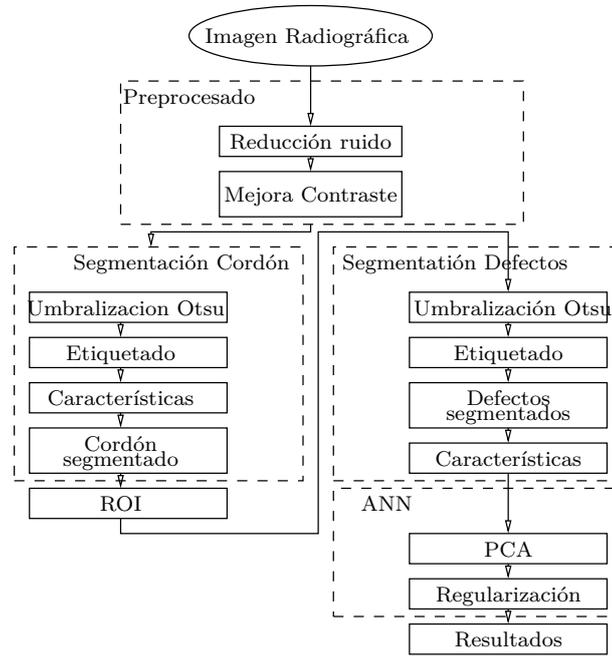
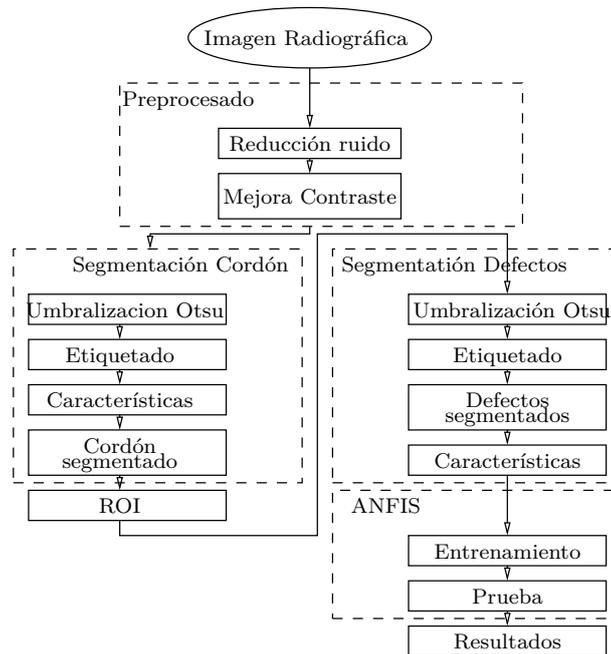


Figura 5.12: Coeficientes de correlación para cada clase de defecto y para cada combinación de vector de características



(a)



(b)

Figura 5.13: Arquitectura de los sistemas clasificadores basados en: (a) ANN y (b) ANFIS.

---

## Conclusiones y Principales Aportaciones

---

La inspección radiográfica de uniones soldadas constituye una técnica de control de calidad que hoy día se ha hecho indispensable en sectores industriales como el nuclear, naval, químico o aeronáutico, siendo particularmente importante en aplicaciones críticas en las que un fallo en una soldadura puede resultar catastrófico.

El problema de la inspección radiográfica presenta, en general, un alto nivel de complejidad, lo que ha condicionado que esta tarea sea llevada a cabo en exclusiva por expertos que basan la eficiencia de su dictamen en la experiencia obtenida del examen de casos similares a lo largo de años.

La dificultad de disponer de expertos capaces de identificar y valorar los defectos en uniones soldadas, y lo costoso del proceso de formación, justifican los esfuerzos de automatización en este campo. Sin embargo, el deseable desarrollo de sistemas para incrementar la objetividad, consistencia, precisión y eficiencia de la inspección radiográfica, choca con el obstáculo de tener que traducir las impresiones subjetivas del experto en información computable.

Es en este campo de la automatización de la inspección de imágenes radiográficas de uniones soldadas donde se ha situado el trabajo desarrollado en esta Tesis Doctoral, cuyo objetivo puede resumirse en el estudio, implementación y validación de un conjunto de técnicas dirigidas a dicha automatización, con especial énfasis en la aplicación de soluciones de *soft-computing* para resolver el problema de la clasificación de defectos.

Como consecuencia del trabajo desarrollado en pos de este objetivo, pueden enumerarse las siguientes conclusiones y principales aportaciones:

1. Como toda actividad de investigación, ésta se ha iniciado con la identificación y definición del problema, concretamente el de la inspección automática de radiografías de uniones soldadas, y con la necesaria revisión de las soluciones propuestas en la literatura. En este sentido, se ha realizado una revisión exhaustiva de los trabajos más relevantes de los últimos años, analizando cada una de las técnicas y procedimientos utilizados para dar solución a las diversas etapas que componen este tipo de sistemas. Como consecuencia de esta revisión se puede concluir que no existe una arquitectura de referencia aceptada por una mayoría de autores. Más bien hay que hablar de una diversidad considerable de técnicas heurísticas adaptadas a las especificidades de la aplicación. Existen ciertas concordancias, no obstante, en cuanto al tipo de características que se definen de cara a la identificación de heterogeneidades en el cordón de soldadura, apreciándose asimismo una tendencia generalizada al uso de soluciones conexionistas para la clasificación de los defectos.
2. Como parte de las etapas de preprocesamiento, hemos implementado técnicas eficientes para la atenuación del ruido, mejora del contraste y realce de las ca-

racterísticas discriminantes. A este fin, en una primera fase se aplicó un filtro adaptativo de Wiener y un filtro Gaussiano paso-bajo rotacional simétrico, y en una segunda fase se implementó un algoritmo de ajuste de los valores de intensidad de la imagen a un rango específico. Tras la aplicación de estas técnicas de preprocesamiento se han obtenido imágenes mucho más adecuadas para la aplicación de las siguientes fases del sistema automático de identificación de defectos.

3. Una de las etapas críticas de cara a conseguir una buenas prestaciones en la identificación de defectos es la segmentación o delimitación del cordón de soldadura. Para acometer esta tarea se han desarrollado e implementado tres procedimientos. El primero de ellos utiliza información local extraída de ciertos perfiles de la imagen radiográfica. Mediante la aplicación de técnicas de umbralización adaptativa, e introduciendo conocimiento del dominio, se superan los inconvenientes asociados a las técnicas de umbralización fija. A esta técnica la hemos denominado *técnica de segmentación basada en perfiles*. La segunda propuesta se sitúa en el campo de la interpretación de imágenes basada en conocimiento, y en ella el proceso de análisis se realiza en tres niveles de abstracción, en los que se va inyectando de forma progresiva conocimiento del dominio. Éste se utiliza de forma implícita en el nivel intermedio y de forma explícita en el nivel más alto. A este propuesta se la ha denominado *técnica de segmentación progresiva*. El tercer procedimiento para la segmentación del cordón de soldadura aplica técnicas de umbralización óptima y etiquetado de componentes conectados para delimitar la región que constituye el cordón de soldadura. A esta tercera propuesta la hemos denominado *técnica de segmentación por etiquetado de componentes conectados*. De entre las tres técnicas implementadas para la segmentación del cordón de soldadura, es precisamente esta última la que mejores resultados ofrece al ser comparadas con la delimitación que realiza el experto, obteniéndose una semejanza media del 89 %.
4. Se ha desarrollado e implementado una técnica para la detección y delimitación automática de las heterogeneidades, que sigue un procedimiento análogo a la tercera propuesta desarrollada para la segmentación del cordón. Una vez binarizada la imagen mediante segmentación por umbralización, se procede al etiquetado de los componentes conectados y se aplica finalmente un algoritmo de selección de bordes. Este procedimiento se ha mostrado como extremadamente efectivo de cara a identificar todos los posibles defectos en el cordón de soldadura, habiéndose alcanzado una sensibilidad del 100 %.
5. Se han desarrollado e implementado dos procedimientos, uno por cada clasificador empleado, para la selección de un conjunto de propiedades relevantes de las heterogeneidades detectadas de cara a su posterior clasificación. En el primero de ellos, desarrollado para determinar el conjunto óptimo de características que constituirán las entradas del clasificador basado en la red neuronal multicapa, se ha procedido en dos fases: en primer lugar se han identificado un conjunto inicial de características morfológicas y posicionales que resultan máximamente discriminantes de cara a la clasificación de las heterogeneidades; a continuación se ha aplicado un análisis de componentes principales para

---

reducir el número de características y optimizar la información de entrada al clasificador. Con el segundo de los clasificadores, basado en un sistema adaptativo de inferencia neuro-borrosa, la selección de características ha seguido un procedimiento algo diferente; un análisis exhaustivo de todas las combinaciones de las características iniciales ha permitido identificar un grupo reducido de dichas características que permiten alcanzar las mejores prestaciones con este clasificador.

6. Para la clasificación de los defectos se ha utilizado, en primer lugar, una red neuronal artificial multicapa con una capa oculta, en la que se han ensayado diferentes procedimientos para el entrenamiento y la mejora de la generalización. De cara a conseguir los mejores resultados de clasificación, se ha analizado de forma exhaustiva el rendimiento de la red neuronal mediante un análisis de regresión entre la respuesta de la red y los objetivos de clasificación, variando el número de características de entrada, el número de neuronas de la capa oculta y su función de transferencia, y el método de mejora de la generalización. A partir de este análisis se concluye que los mejores resultados se consiguen con una red consistente en una capa de entrada con 11 nodos, una capa oculta con 20 neuronas de función de transferencia sigmooidal, aplicando un método de mejora de la generalización basada en una función de rendimiento modificada con una razón de rendimiento fija de 0.5. El clasificador se ha validado a partir de un conjunto de heterogeneidades extraídas de 86 radiografías de la colección del Instituto Internacional de Soldadura, y los resultados de precisión obtenidos para este clasificador, a partir de la matriz de confusión, arrojan un valor de 0.78 para el conjunto de heterogeneidades clasificadas, valor que puede considerarse satisfactorio si se compara con los obtenidos por otros autores.
7. Se ha desarrollado e implementado un segundo clasificador consistente en una arquitectura basada en un sistema adaptativo de inferencia neuro-borrosa (ANFIS) dividida en cinco secciones, una por cada clase de heterogeneidad. La disminución drástica en el número de entradas respecto a la red neuronal nos ha permitido, en este caso, reducir considerablemente el número de reglas, con el consiguiente ahorro computacional. Se ha elegido para este clasificador una estructura de reglas borrosas de tipo Sugeno, en la que hemos usado una partición de rejilla de los datos para definir tres funciones generalizadas de pertenencia de tipo Gaussiano para cada una de las entradas, funciones que se han ajustado durante el proceso de entrenamiento al igual que los coeficientes de los consecuentes de las reglas. Este clasificador se ha validado con el mismo conjunto de heterogeneidades del clasificador neuronal, y los resultados de precisión obtenidos con sistema proporcionan un valor de 0.82 para el conjunto de heterogeneidades, lo que supone que este clasificador mejora ligeramente los resultados de precisión del clasificador basado en redes neuronales. Esta mejora resulta mucho más evidente si se comparan los valores promedio de rendimiento obtenidos de las tablas de coeficientes de correlación con el dictamen experto, alcanzando en el caso de ANFIS un valor de 0,91, frente a 0,80 del clasificador neuronal.

En cuanto a las líneas futuras que se abren con este trabajo, cabe pensar, en

primer lugar, en ensayar nuevos clasificadores de tipo estadístico o de árbol binario, de cara a comparar sus prestaciones con las de los clasificadores conexionistas implementados en este trabajo. Asimismo, pretendemos investigar nuevas características a extraer de los defectos que complementen las ya utilizadas y aporten una mayor capacidad discriminante. En este sentido, una buena elección de un conjunto representativo de características con alto poder discriminante nos deben permitir abordar una mejora del sistema basada en ampliar la tipología de defectos identificables, así como emprender el diseño de una etapa final de decisión para la aceptación o rechazo de la soldadura inspeccionada en base a las normas internacionales.

Por último, y haciendo previsiones a un plazo más largo, sería muy interesante proyectar el sistema sobre procesadores integrados o arquitecturas digitales dedicadas, de forma que el sistema completo de análisis pudiera acoplarse a sistemas portátiles de radiografía digital para hacer el análisis de las imágenes en campo y en tiempo real.

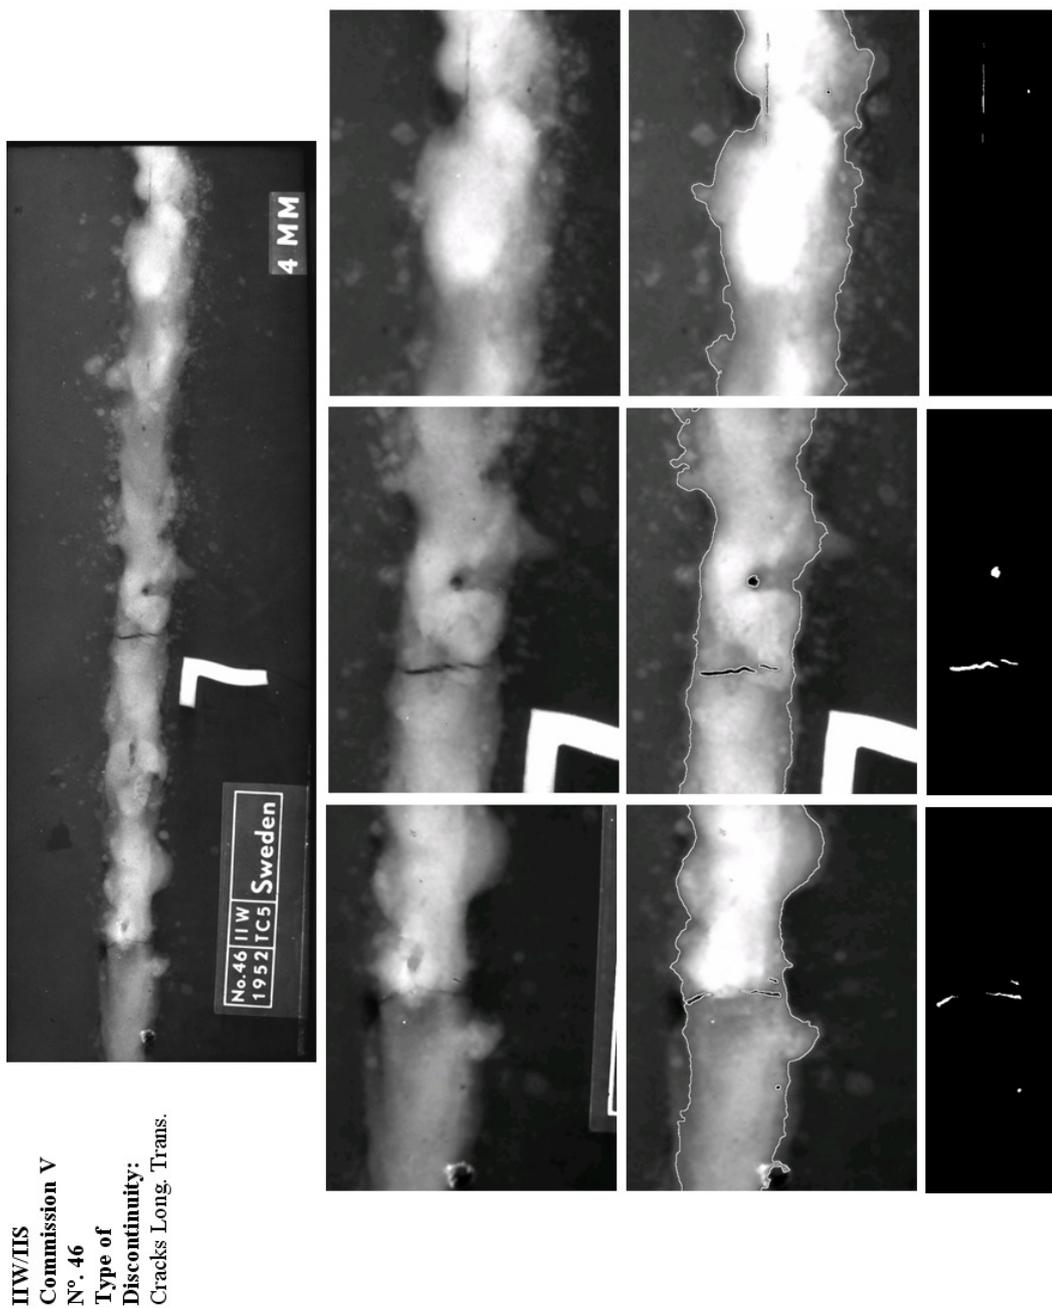
# Apéndice A

---

## Resultados de las Etapas de Segmentación del Cordón de Soldadura y Heterogeneidades.

---

En este apéndice se muestran los resultados más significativos obtenidos en las etapas intermedias de procesado y para la segmentación final de las heterogeneidades para algunas radiografías tomadas como ejemplo. En concreto, se muestra la adquisición de la radiografía del cordón de soldadura o imagen original; las franjas obtenidas después de dividir la imagen original para acomodar el tamaño y la carga computacional para su posterior procesado; a segmentación del cordón sobrepuesto sobre la imagen original; y por último, como son segmentadas las heterogeneidades sobre el rectángulo límite (*bounding box*) obtenido de la segmentación previa del cordón, lo que evita aumentar la carga de procesamiento. Sólo queda comentar que aquellas franjas donde no son descubiertas heterogeneidades no son mostradas.



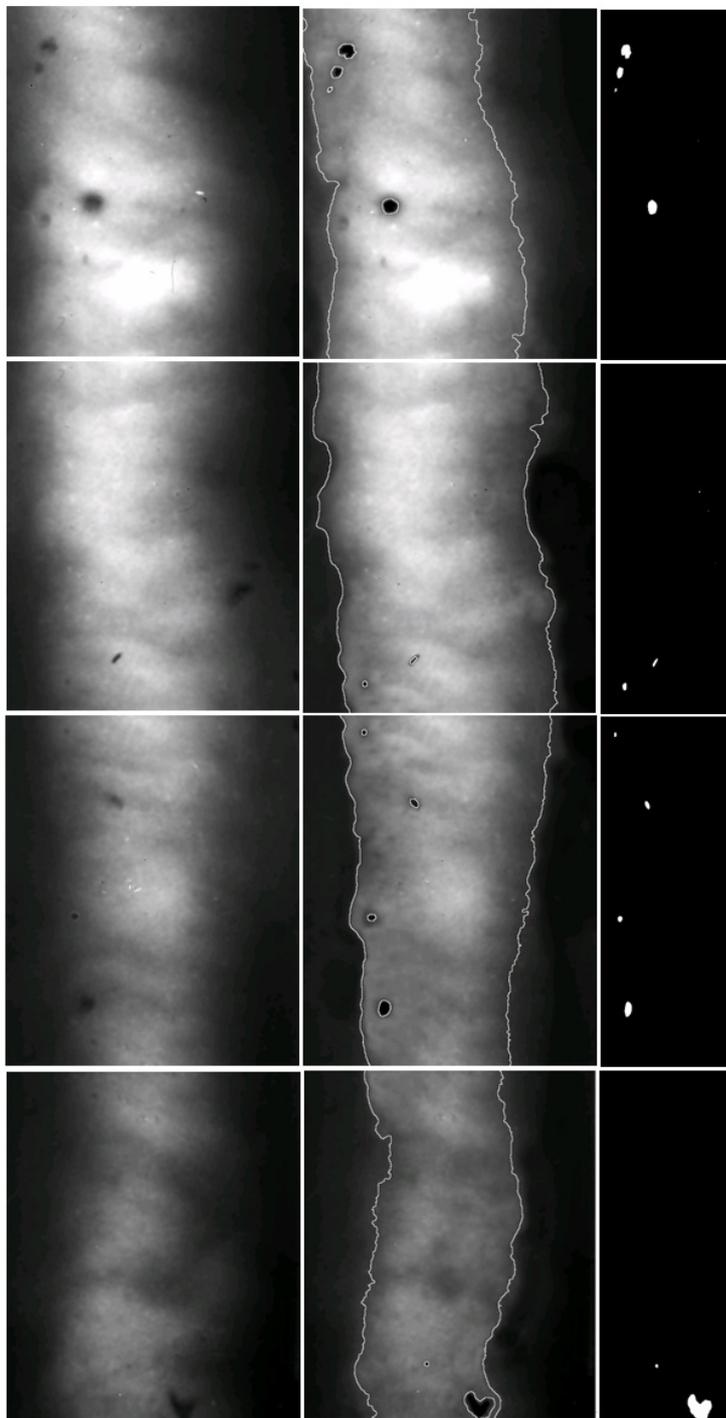
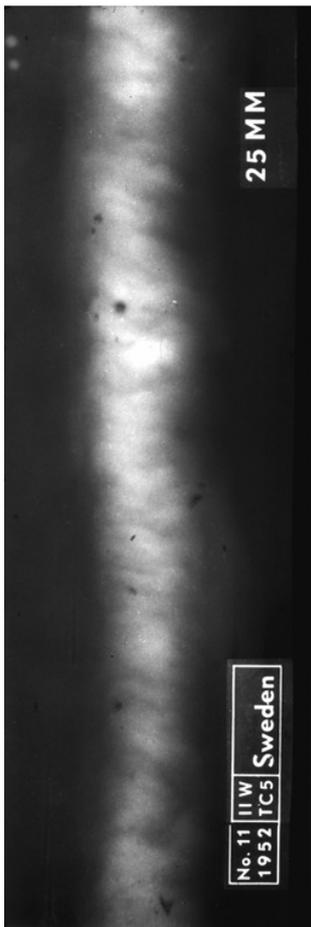
IIW/IIS

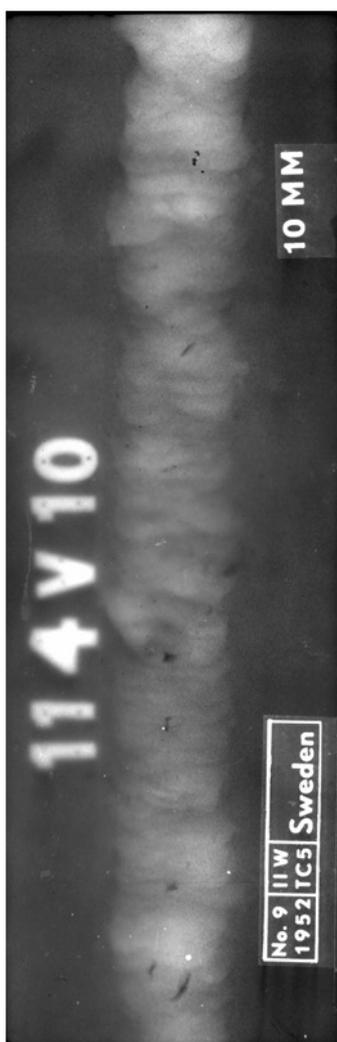
Commission V

Nº. 11

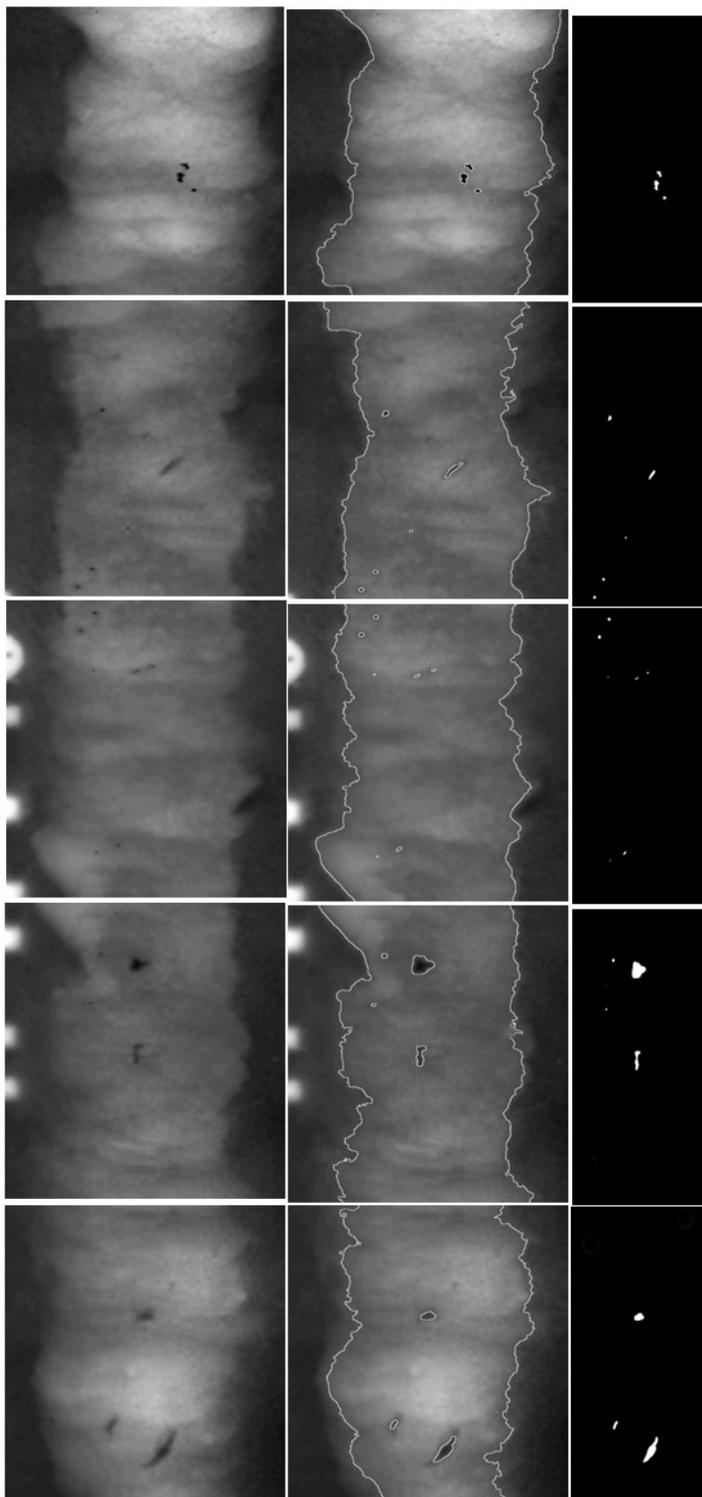
Type of Discontinuity:

Slag inclusions of any shape, in any direction





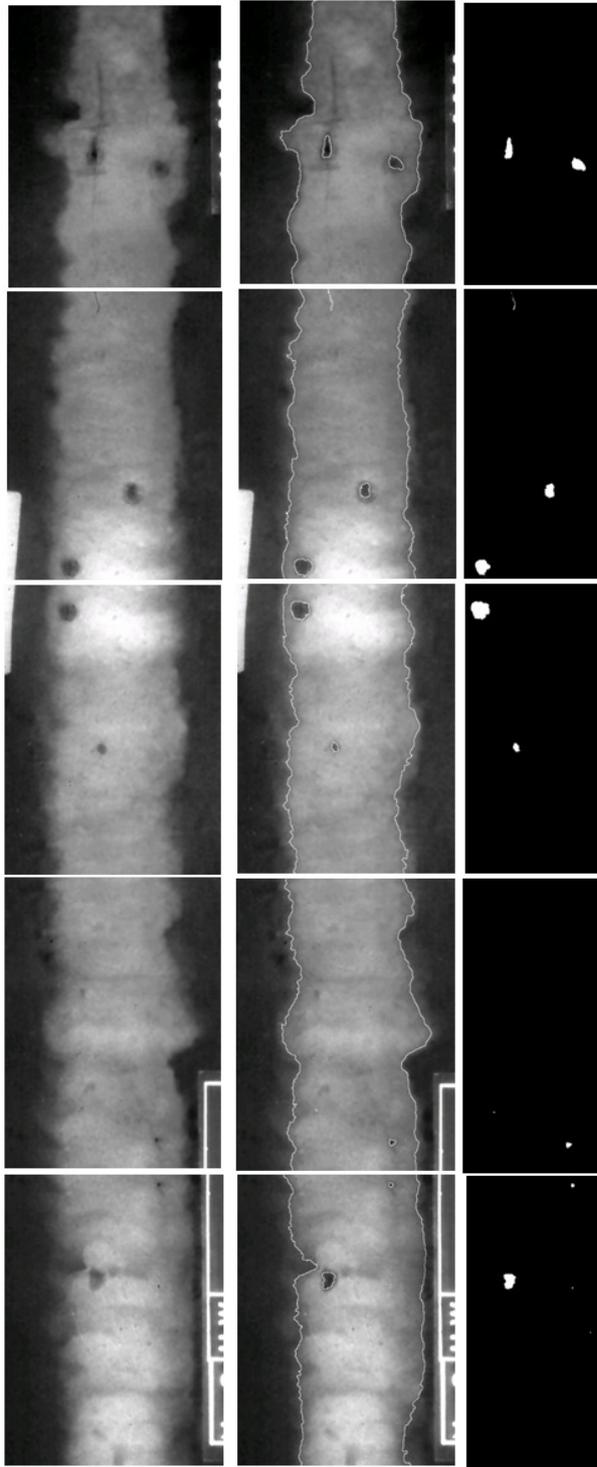
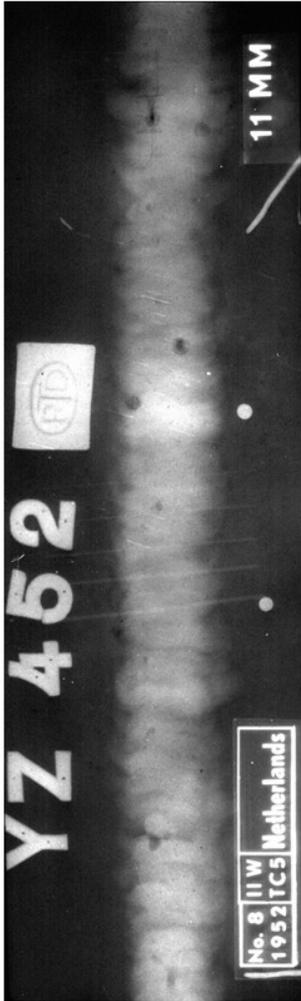
IIW/IIS  
 Commission V  
 N° 9  
 Type of  
 Discontinuity:  
 Slag inclusions of  
 any shape, in any  
 direction.

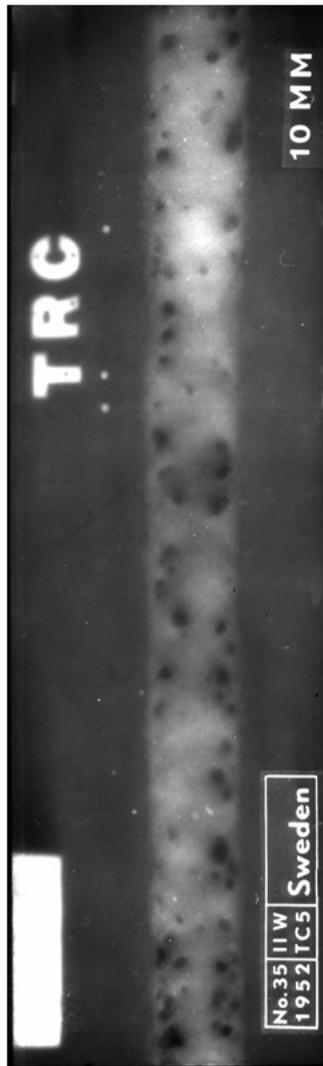


IIW/IS  
Commission V  
N° 8

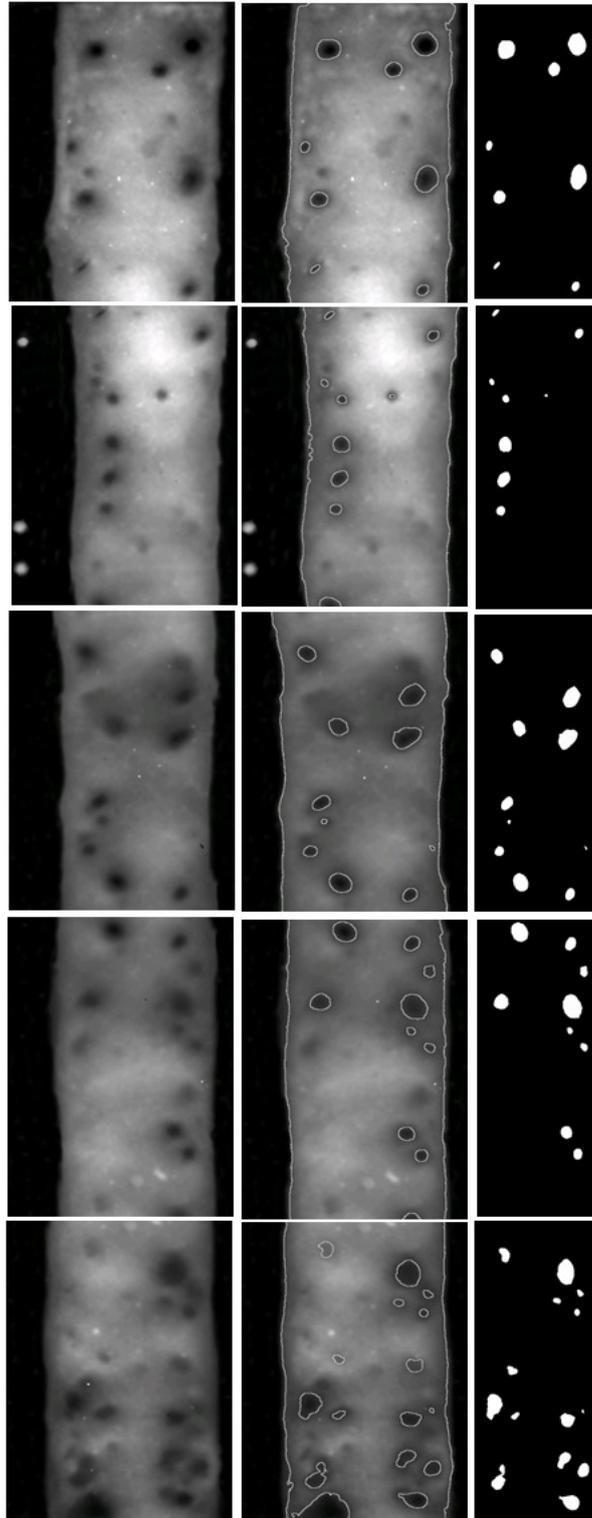
Type of

Discontinuity:  
Slag inclusions of  
any shape, in any  
direction.

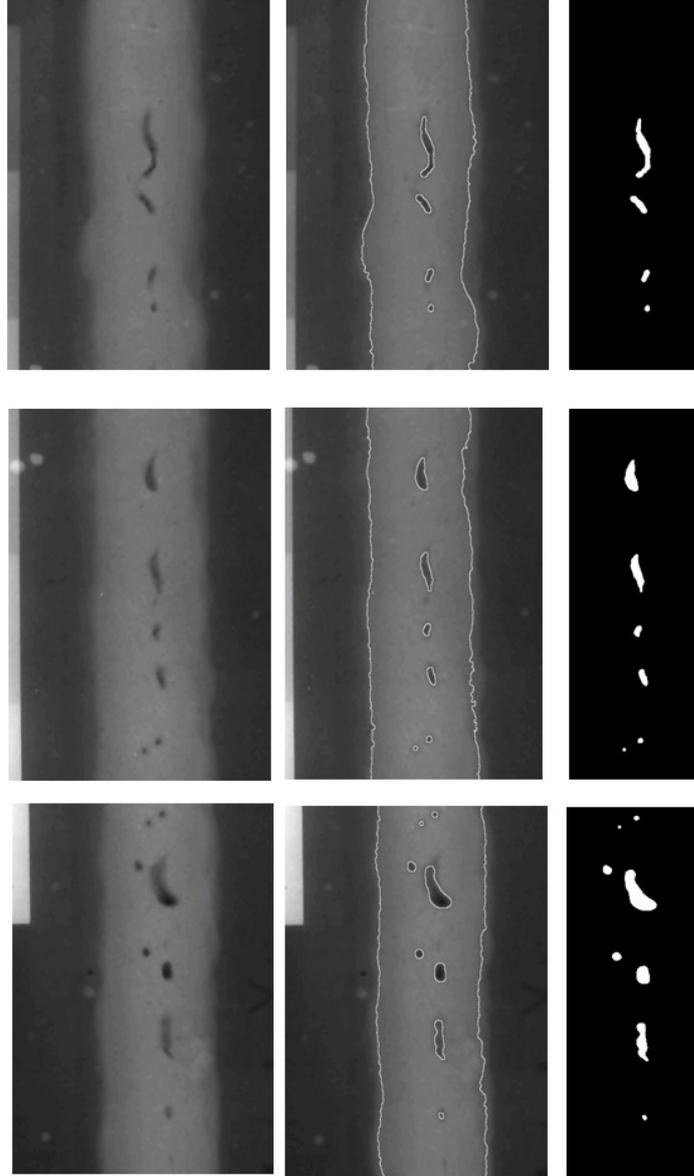
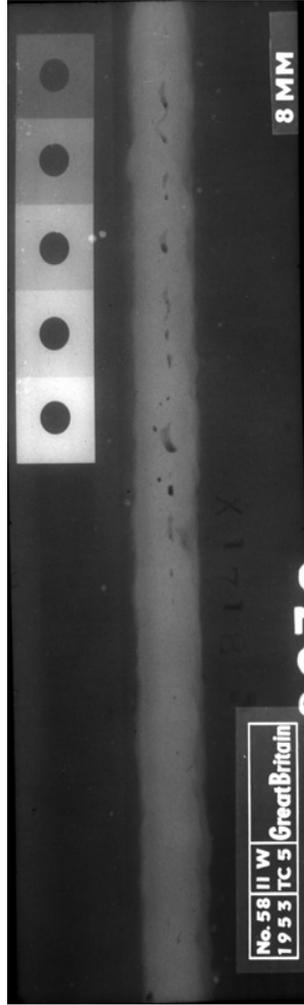


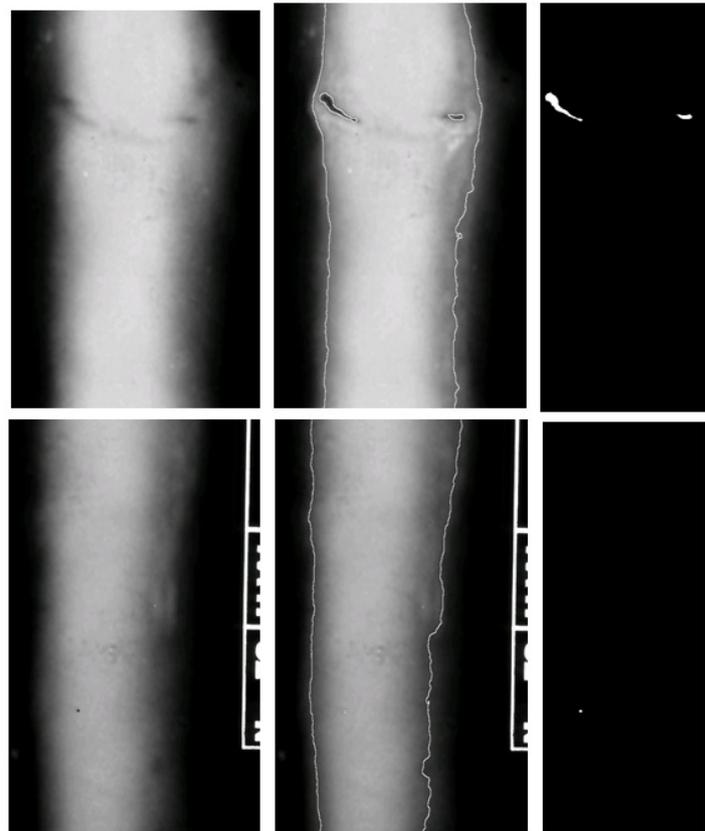
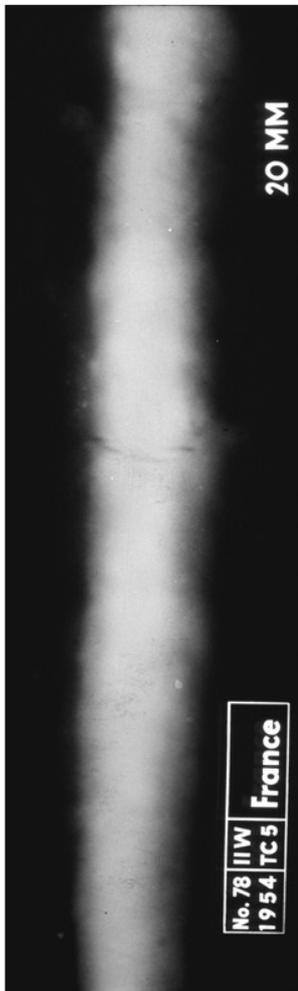


IIW/IIS  
 Commission V  
 N° 35  
 Type of  
 Discontinuity:  
 Porosity. Gas cavities



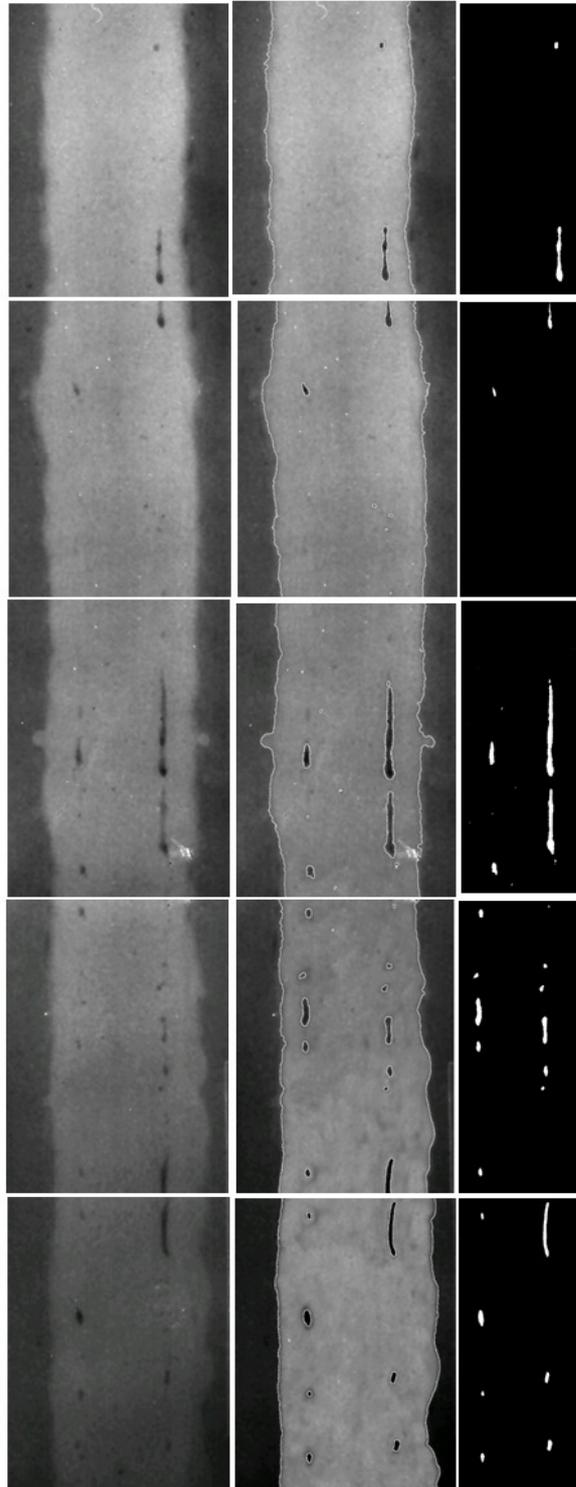
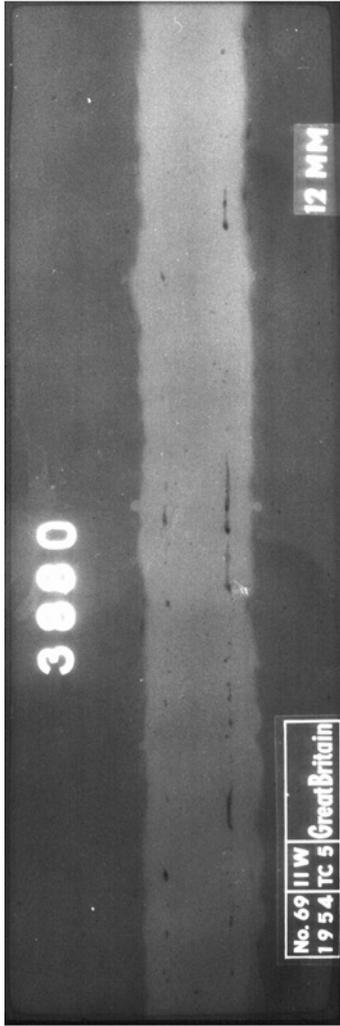
IIW/IIS  
Commission V  
N° 58  
Type of  
Discontinuity:  
Incomplete  
penetration.

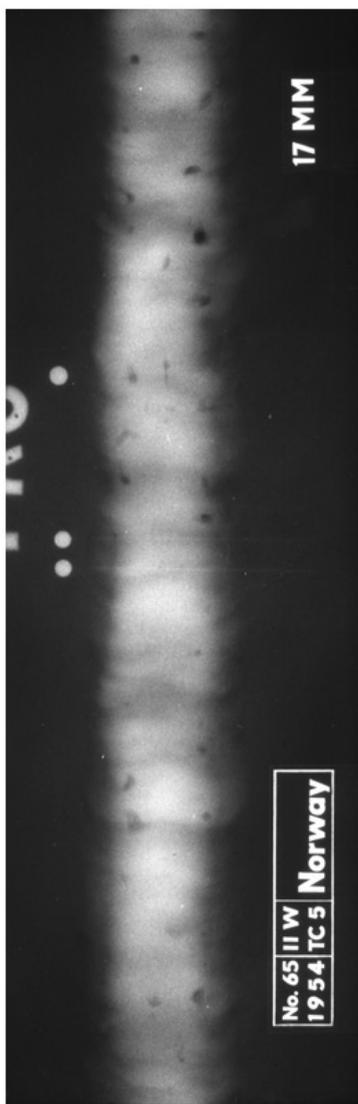




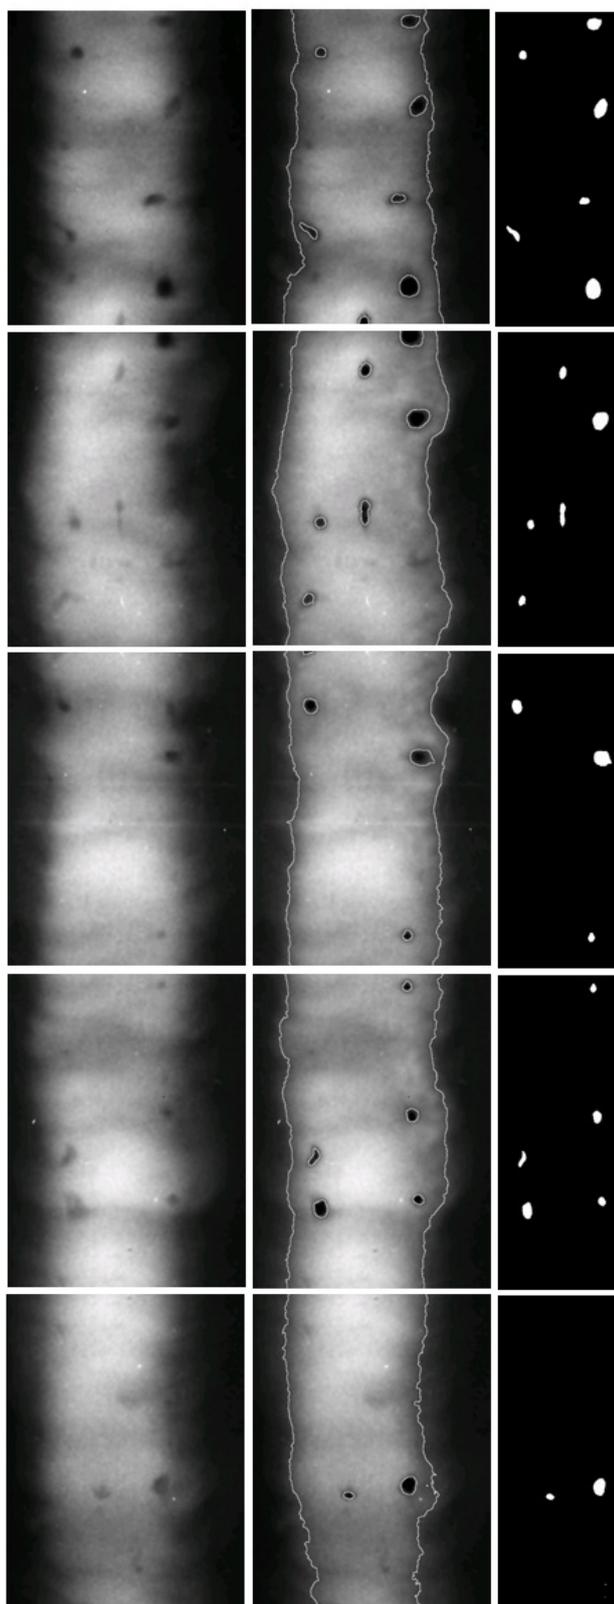
IIW/IIIS  
Commission V  
N° 78  
Type of  
Discontinuity:  
Cracks Long

**IIW/IS**  
**Commission V**  
**N° 69**  
**Type of**  
**Discontinuity:**  
**Slag lines inclusions**

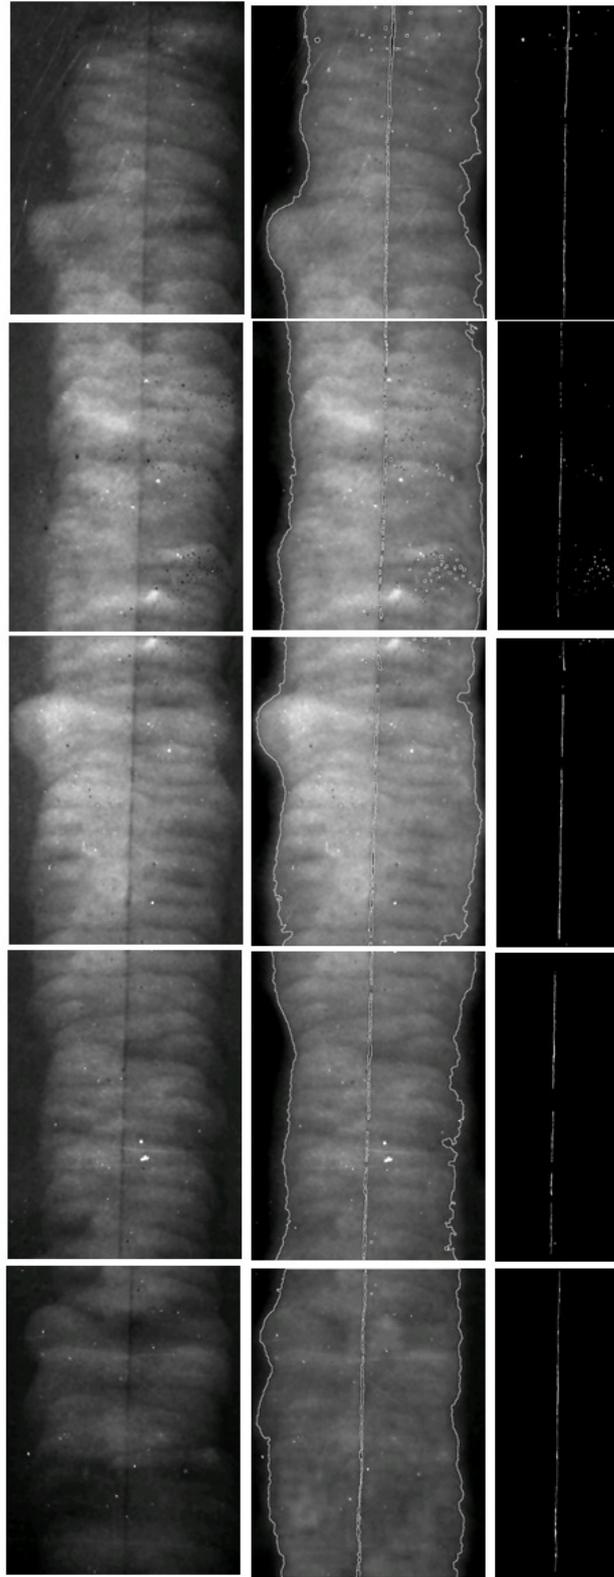




IIW/IIS  
 Commission V  
 N° 65  
 Type of  
 Discontinuity:  
 Slag inclusion.

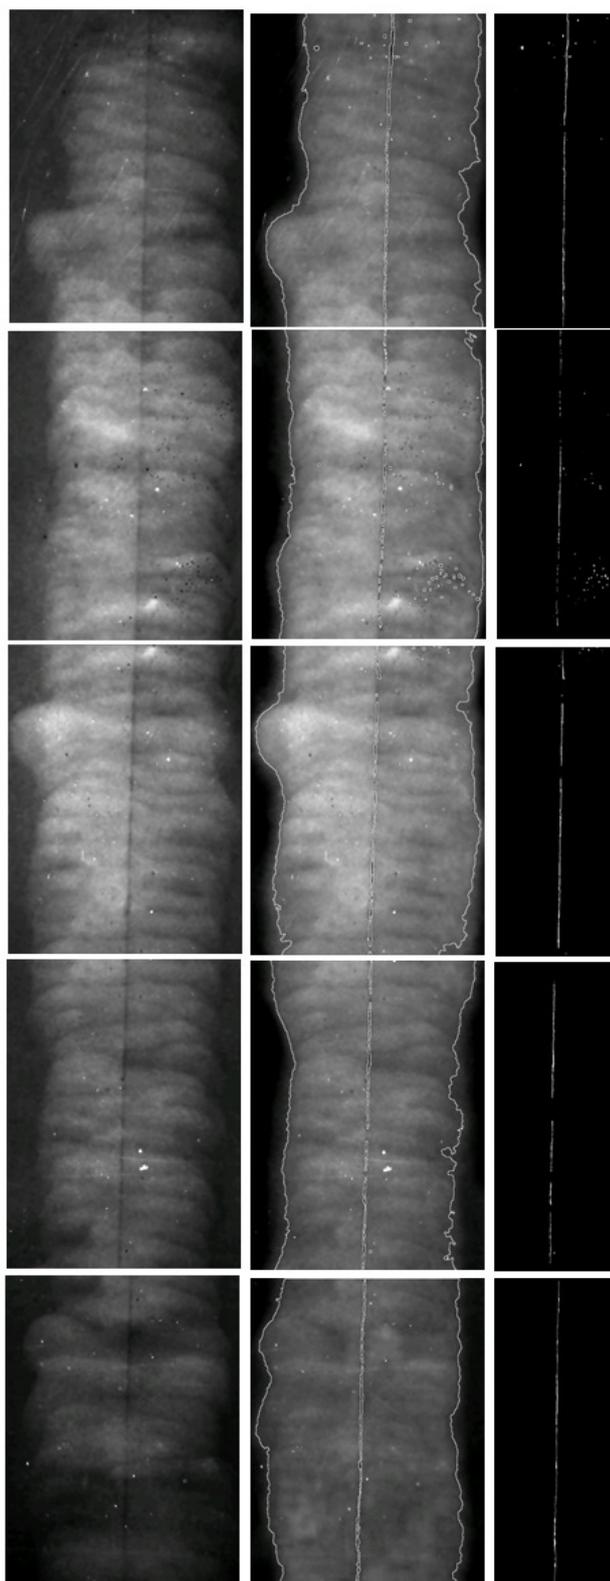


IIW/IIS  
Commission V  
N° 42  
Type of  
Discontinuity:  
Lack of fusion

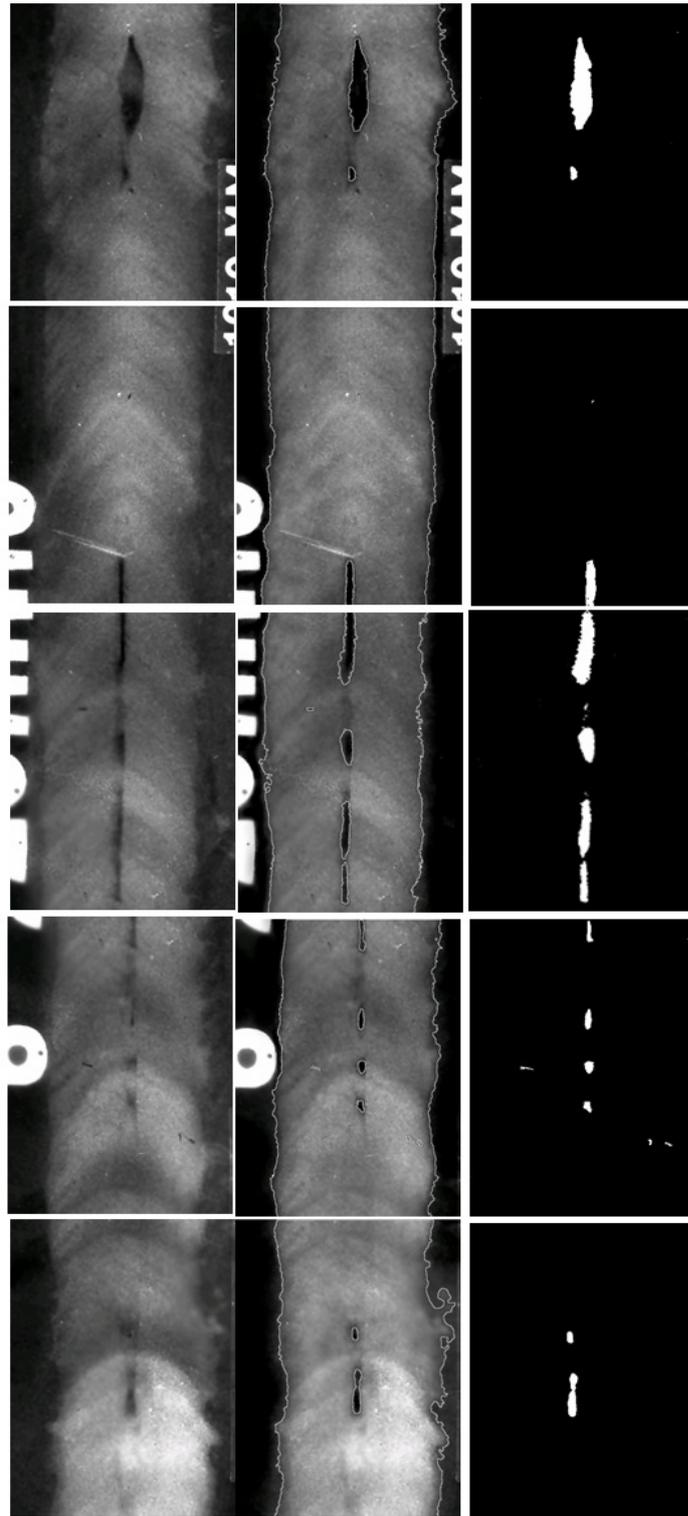


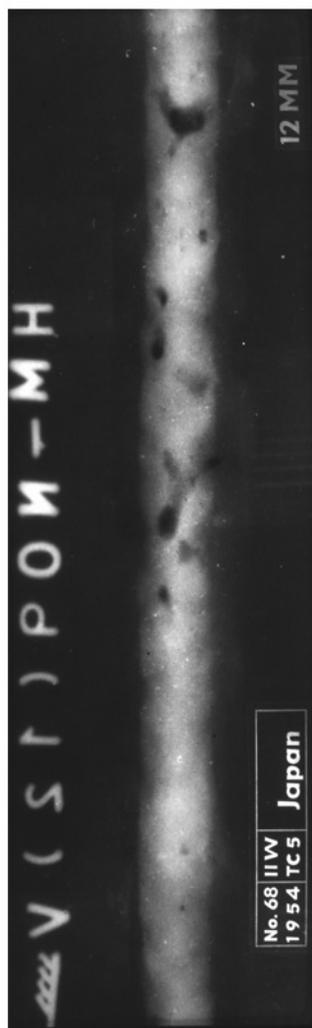


IIW/IS  
Commission V  
N° 42  
Type of  
Discontinuity:  
Lack of fusion

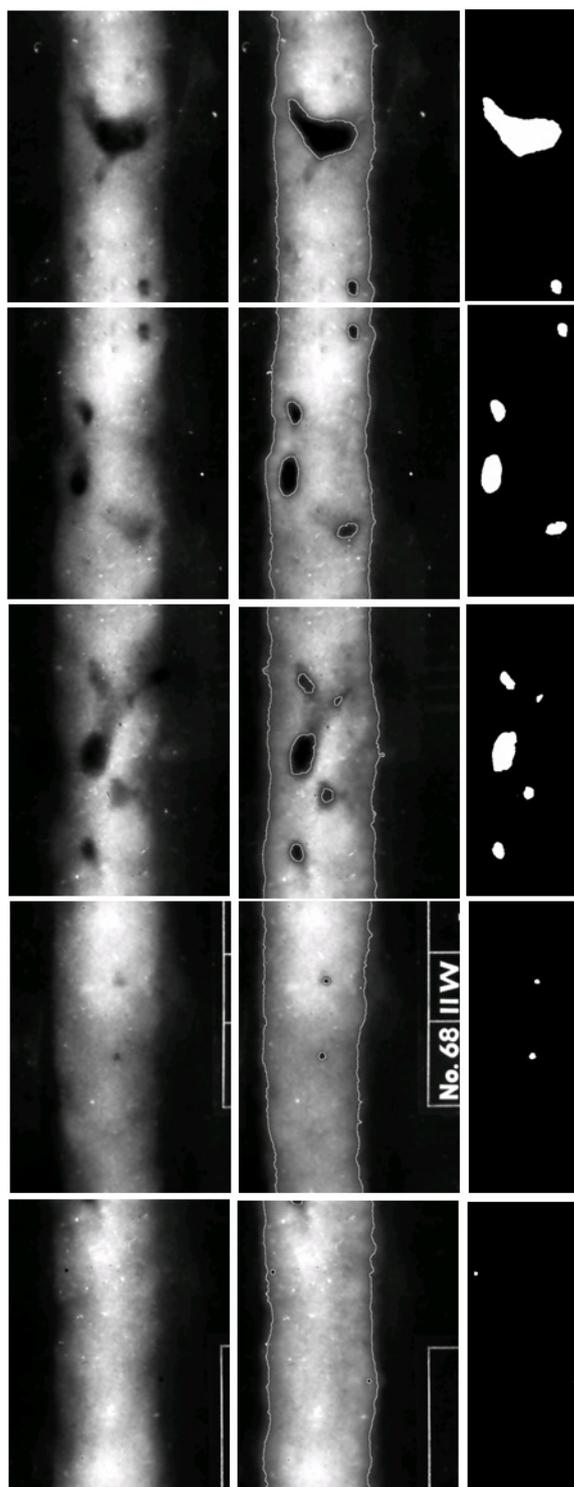


IIW/IS  
Commission V  
N° 29  
Type of  
Discontinuity:  
Incomplete  
penetration

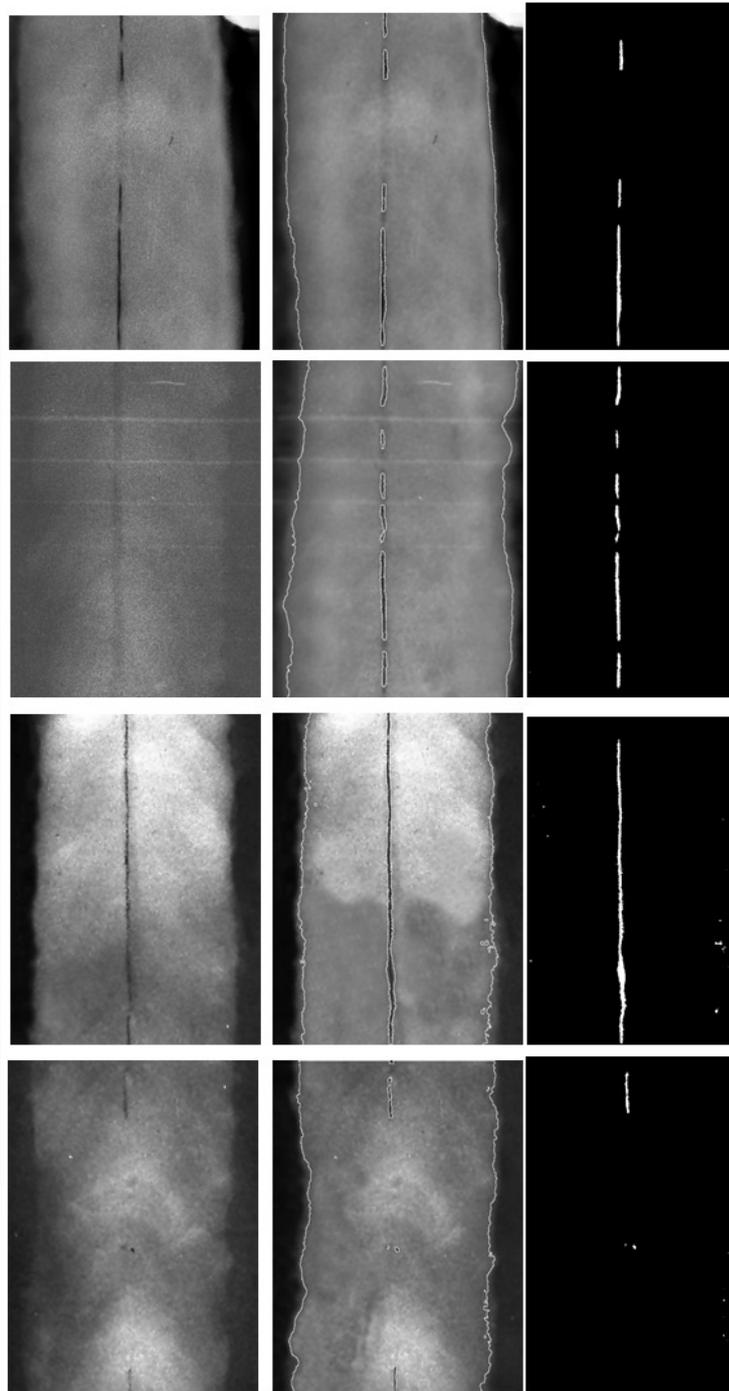
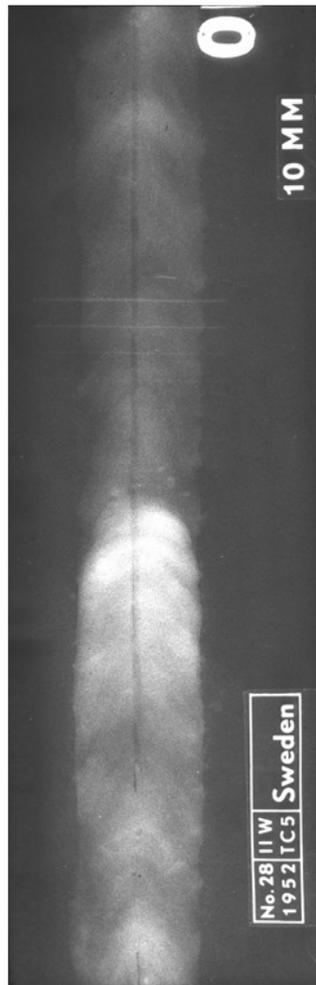




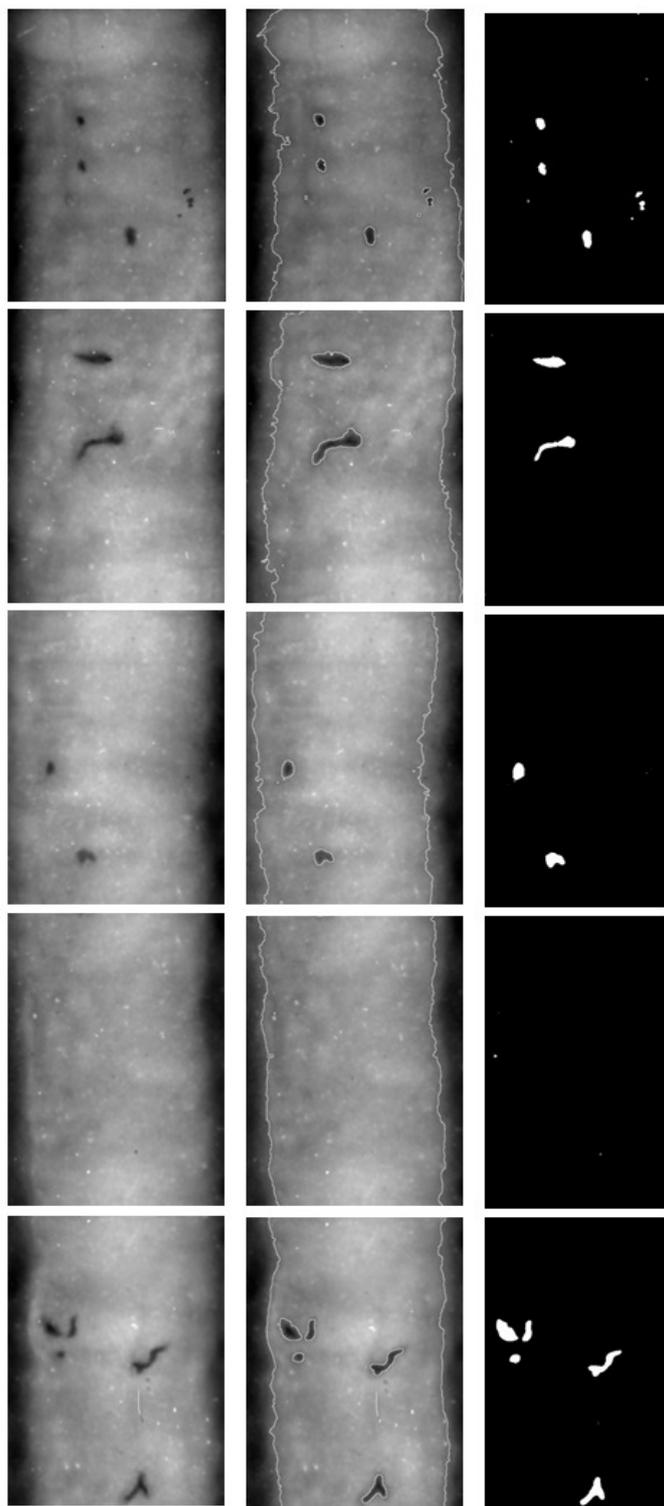
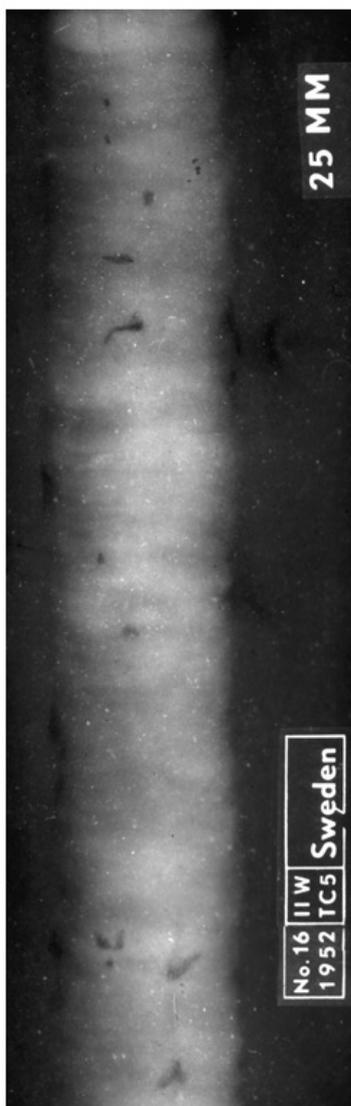
IIW/IIS  
 Commission V  
 N° 68  
 Type of  
 Discontinuity:  
 Slag inclusions of  
 any shape, in any  
 direction.



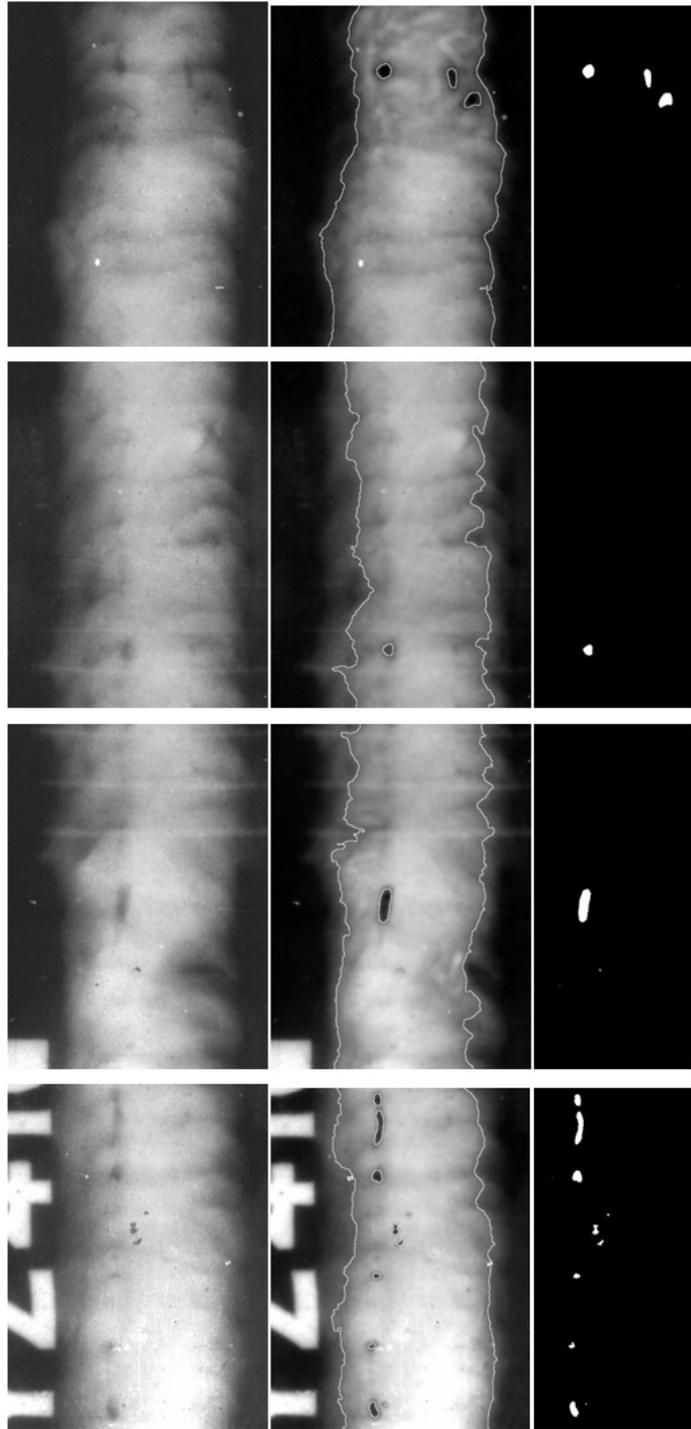
IIW/IIS  
Commission V  
N° 28  
Type of Discontinuity:  
Falta de penetración

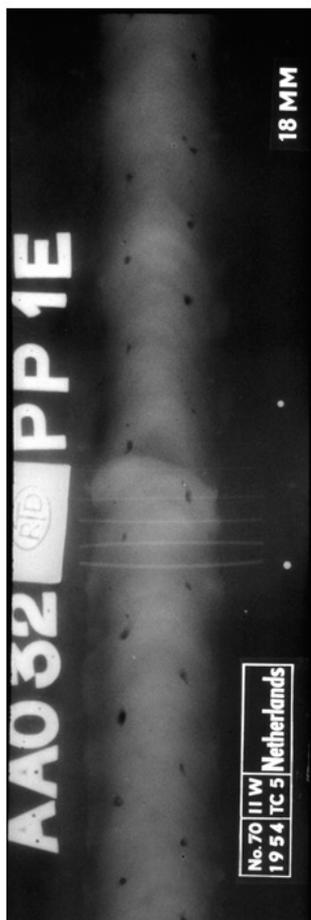


IIW/IIS  
Commission V  
Nº 16  
Type of Discontinuity:

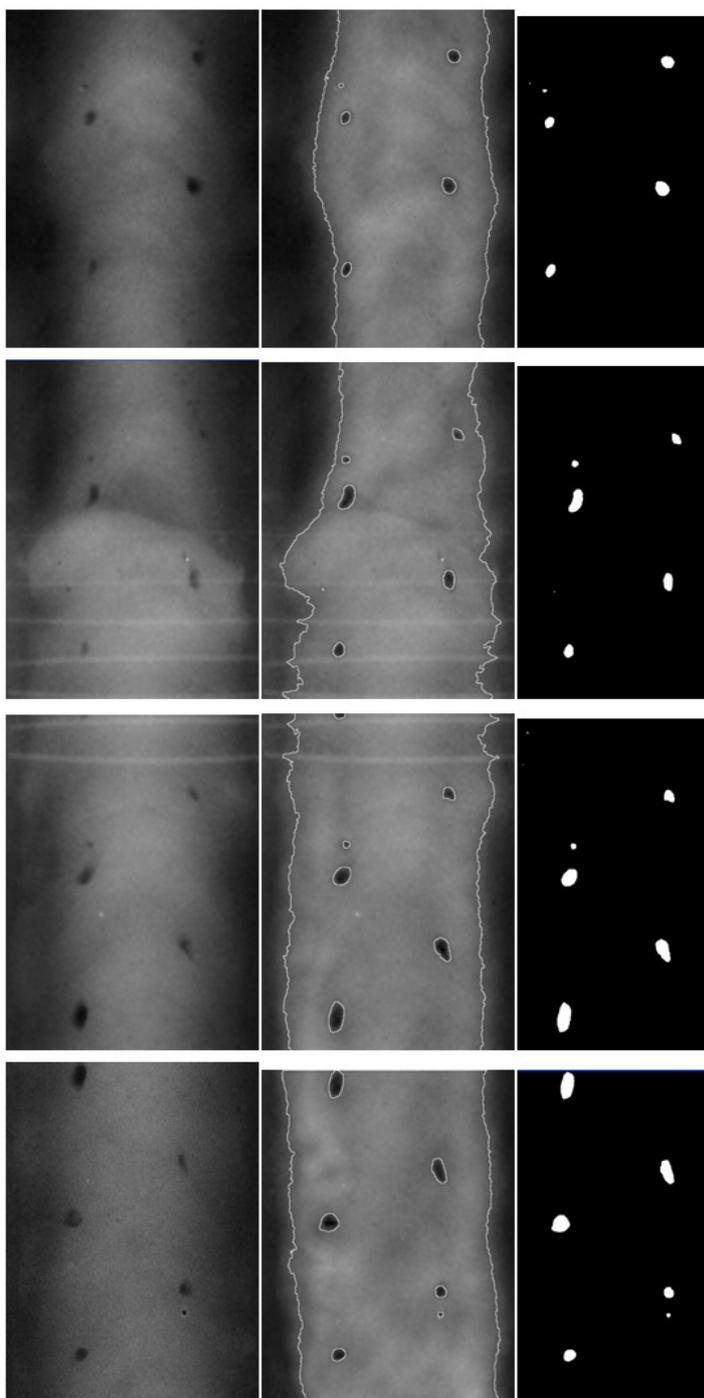


IIW/IIS  
Commission V  
N° 17  
Type of Discontinuity:

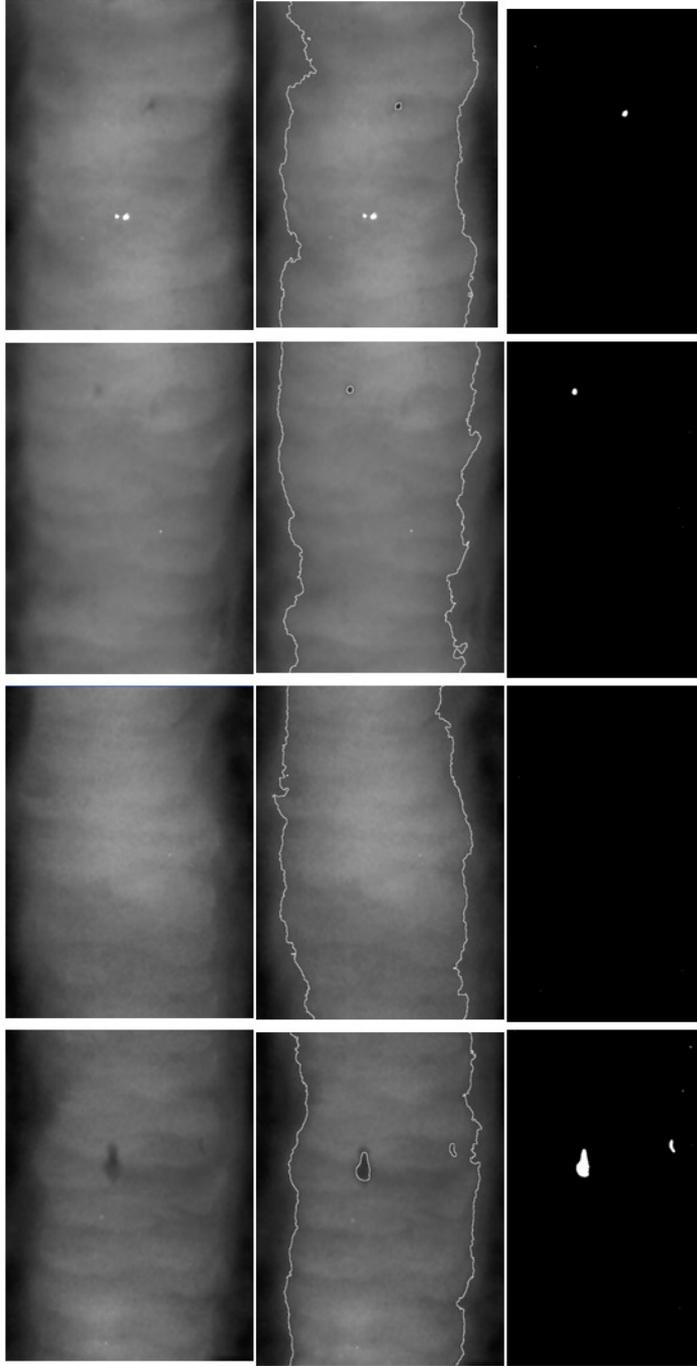
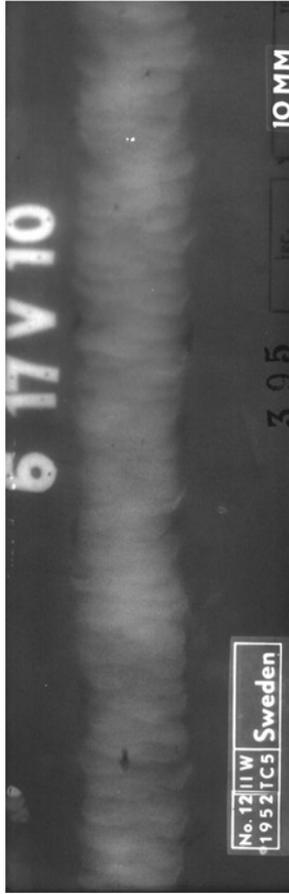




IIW/IS  
Commission V  
N° 70  
Type of Discontinuity:

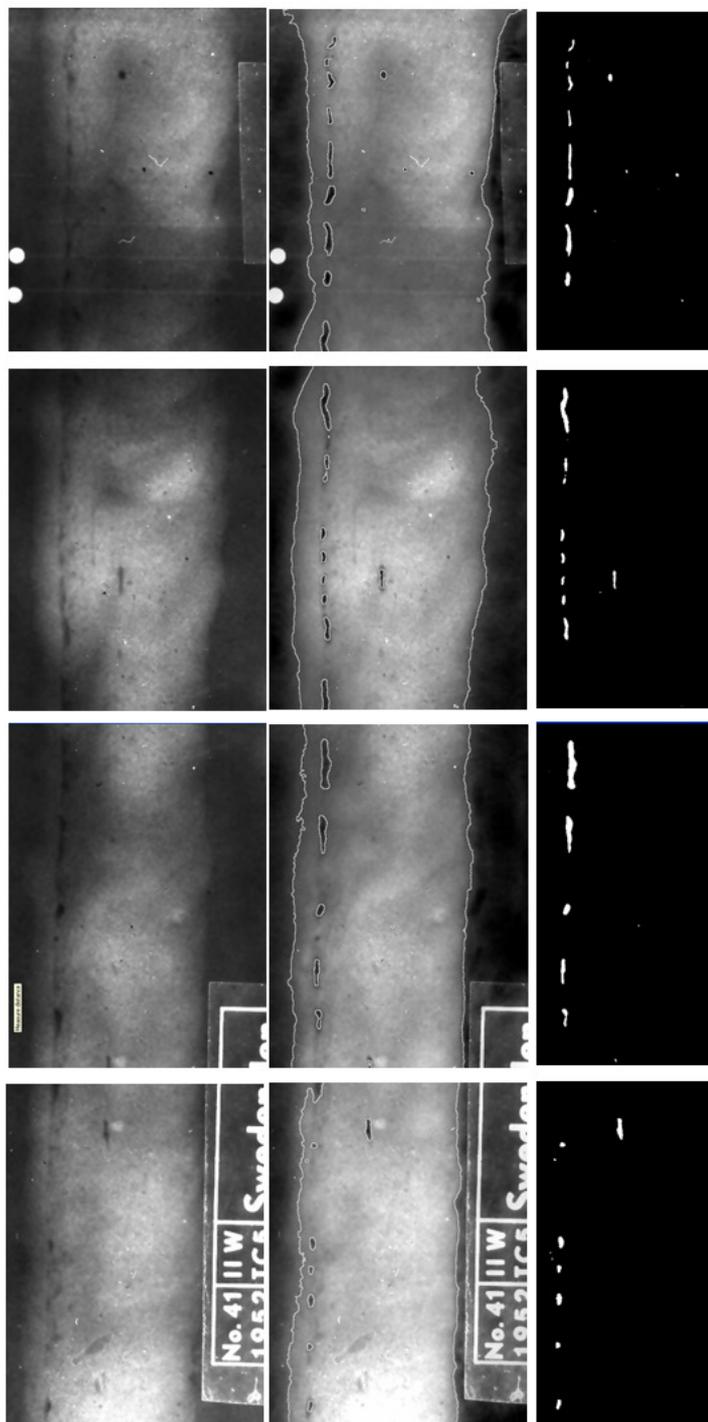


IIW/IIS  
Commission V  
N° 12  
Type of Discontinuity:

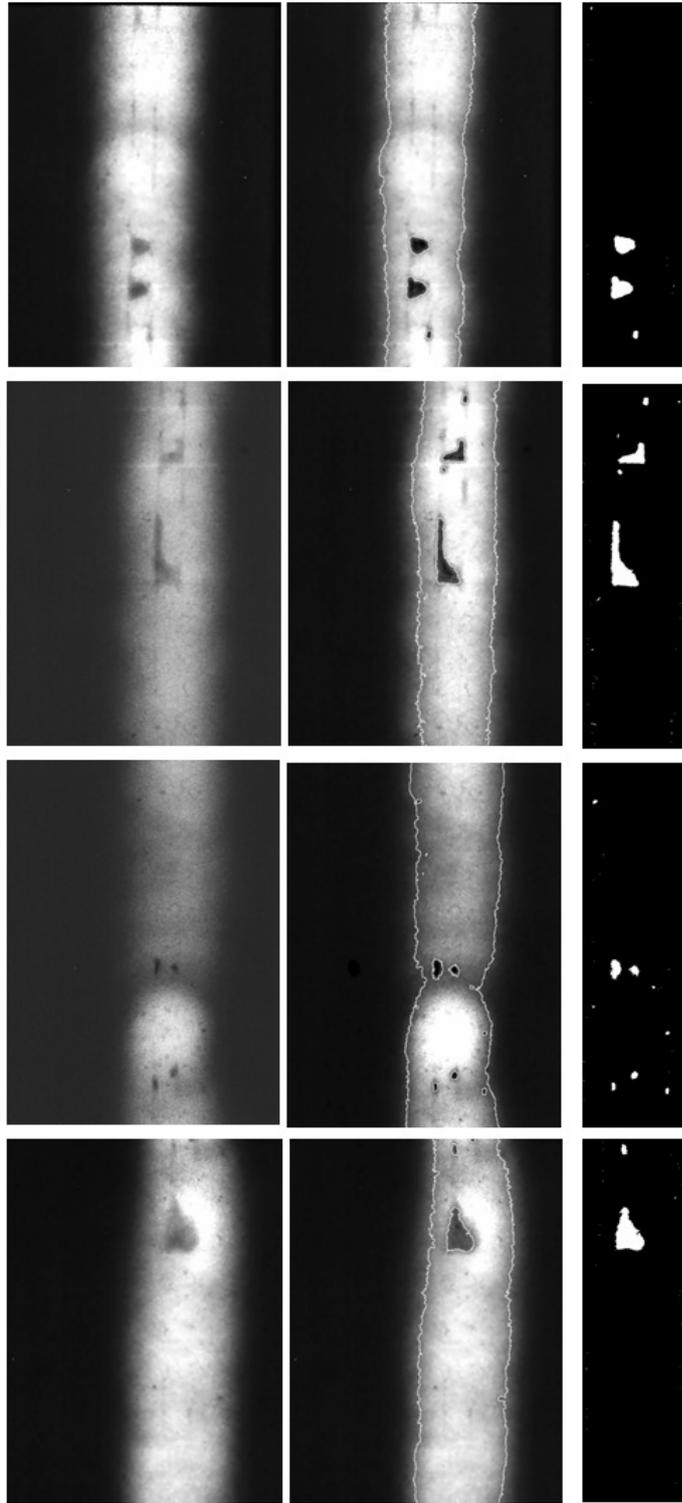
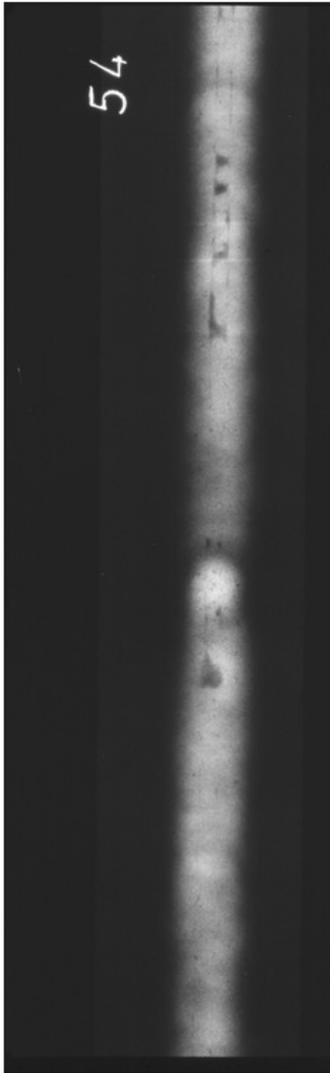


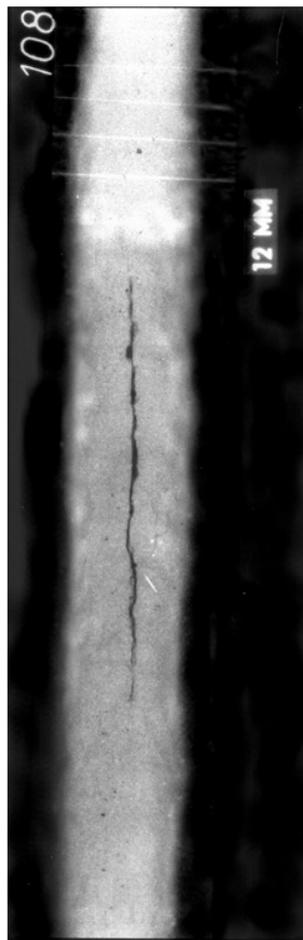


IIW/IIS  
Commission V  
Nº 41  
Type of Discontinuity:  
Falta de fusión

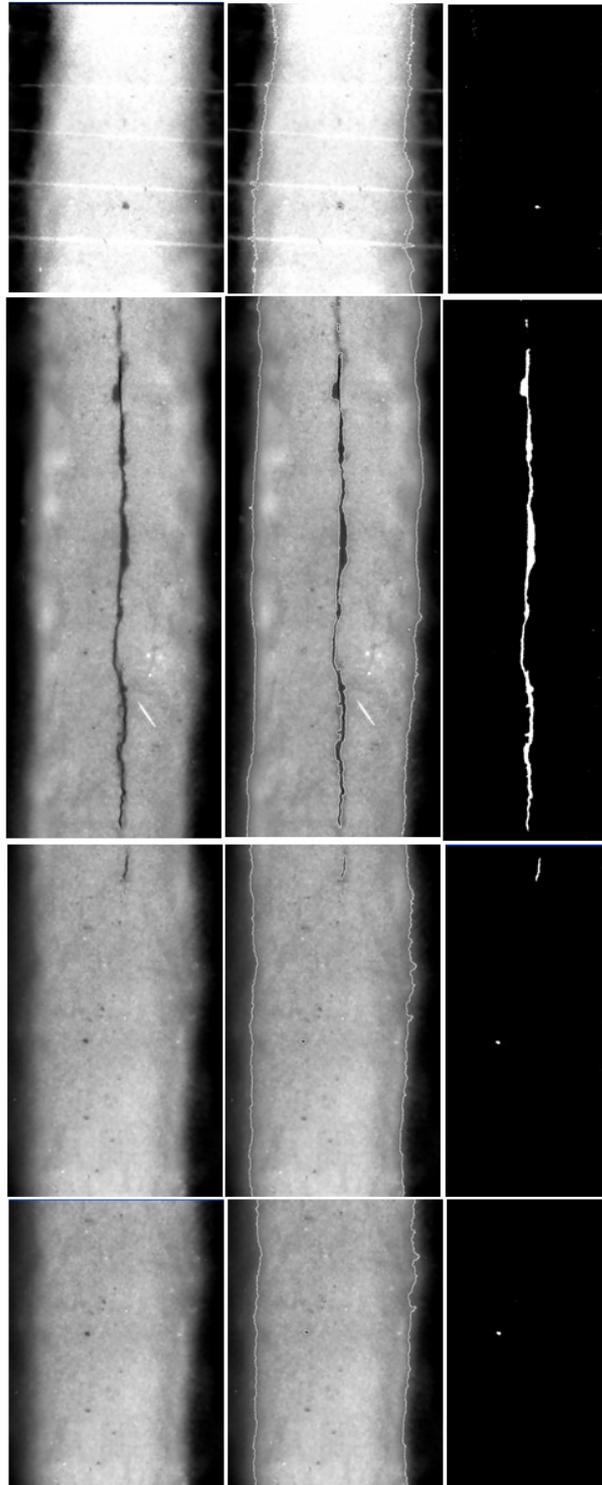


IIW/IIS  
Commission V  
N° novo\_2\_54  
Type of  
Discontinuity:  
Falta de fusão

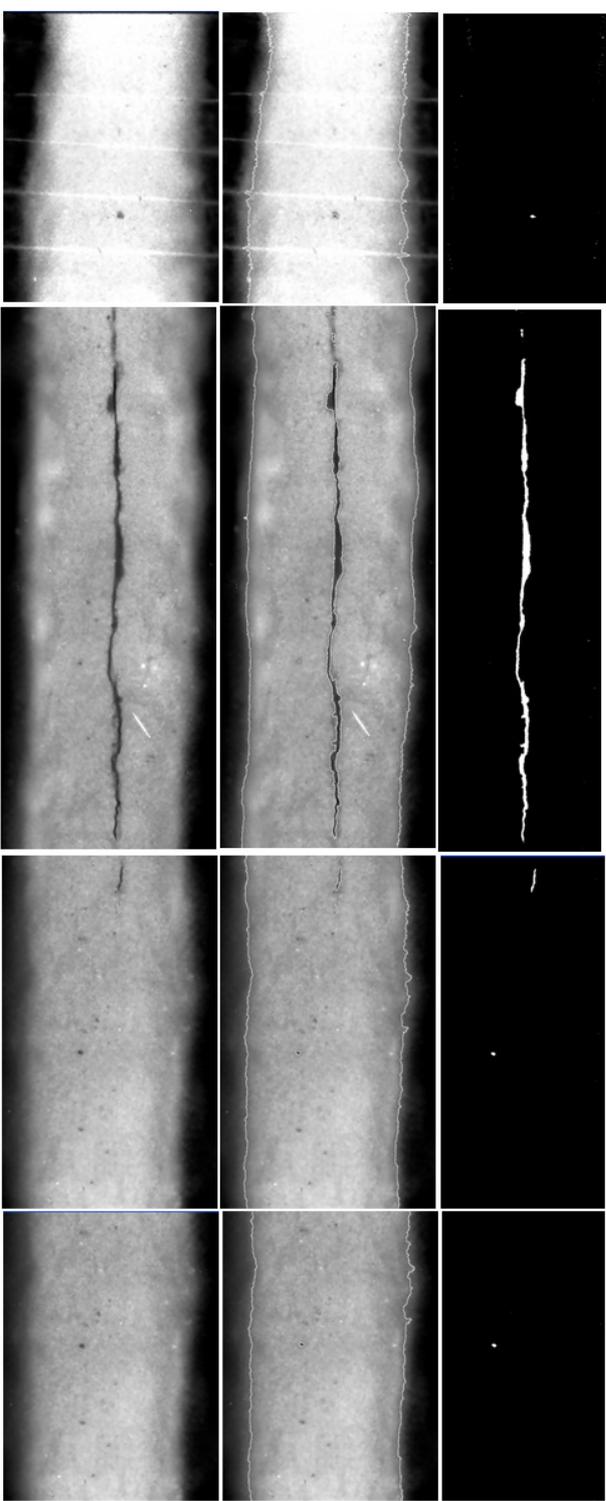
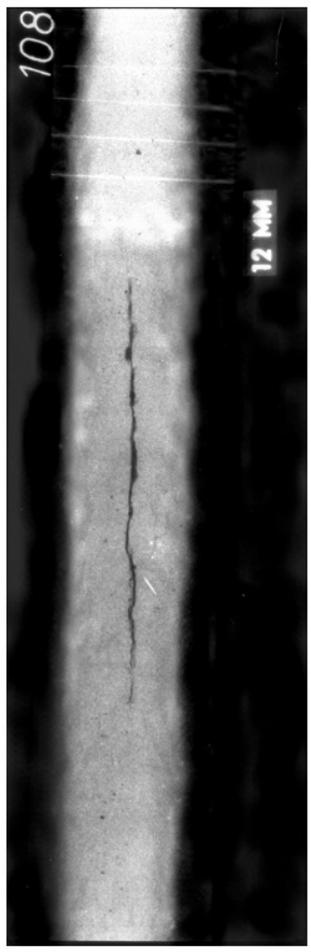


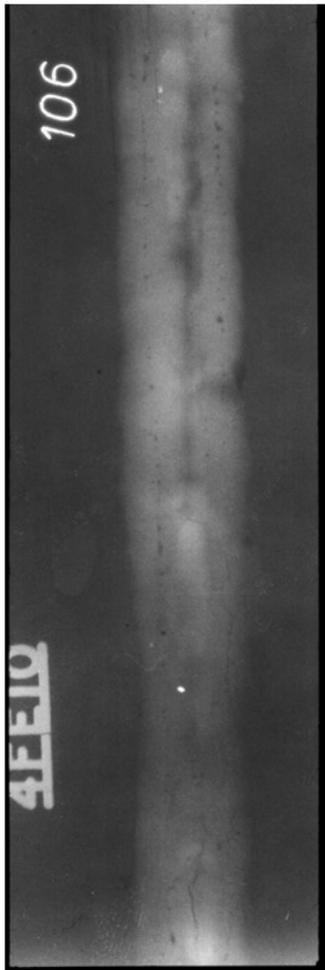


IIW/IIS  
Commission V  
Nº novo\_2\_108  
Type of  
Discontinuity:  
Grietas

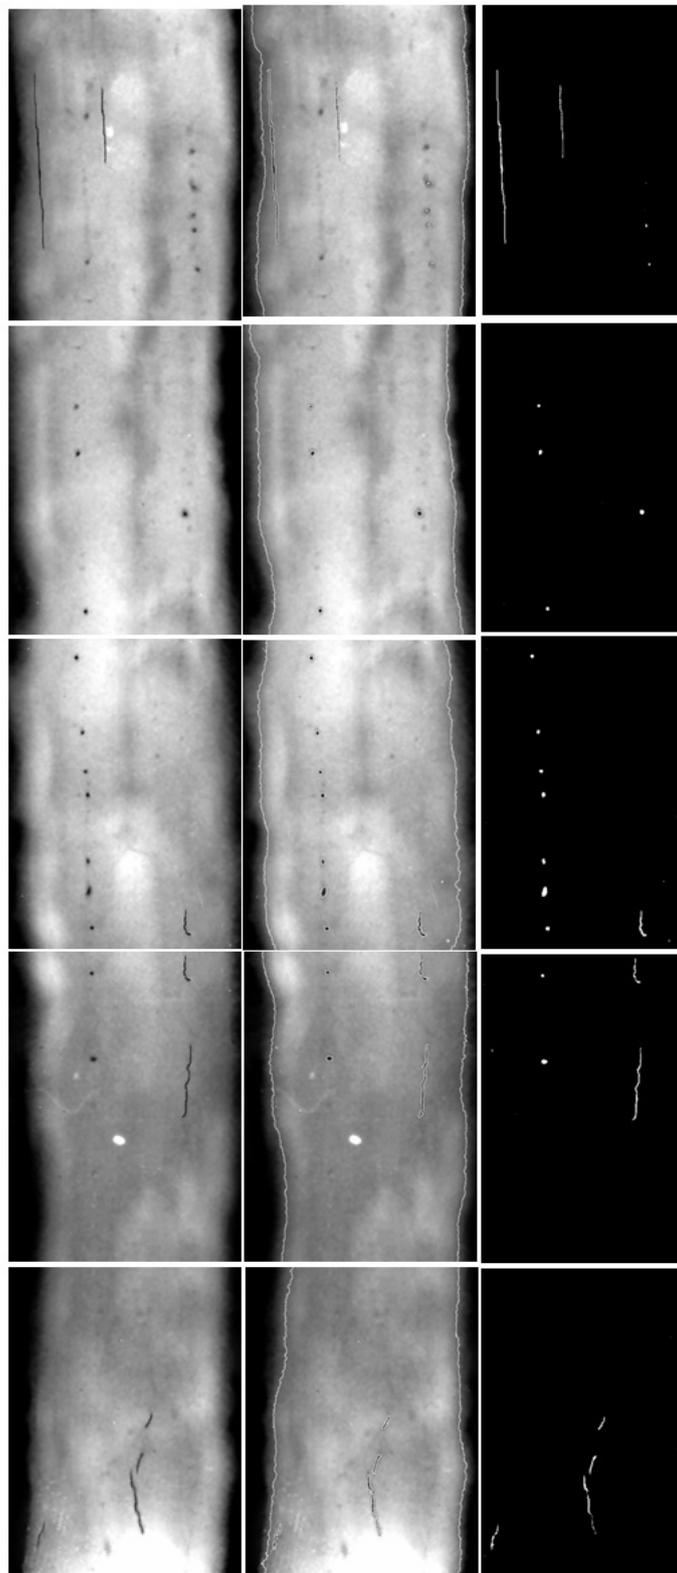


IIW/IIS  
Commission V  
Nº novo\_2\_108  
Type of  
Discontinuity:  
GrietasQ

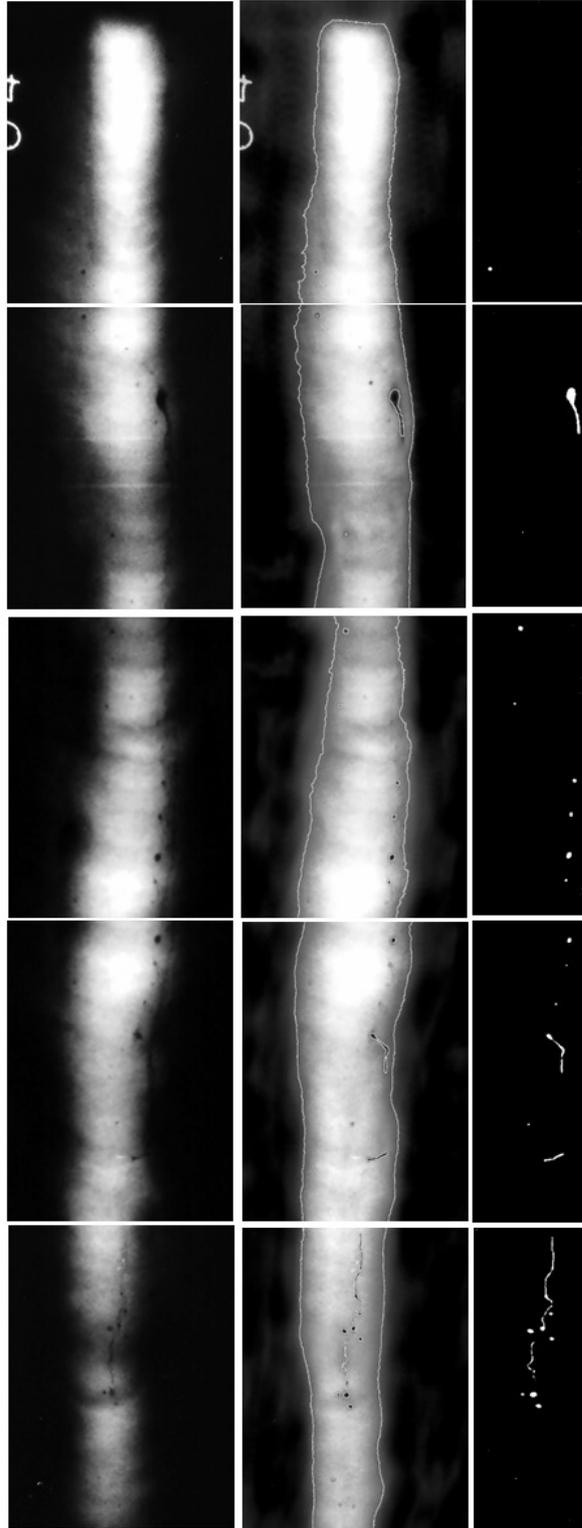
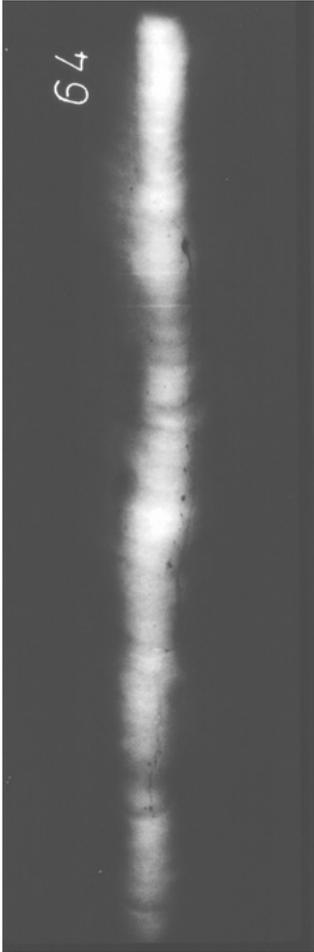


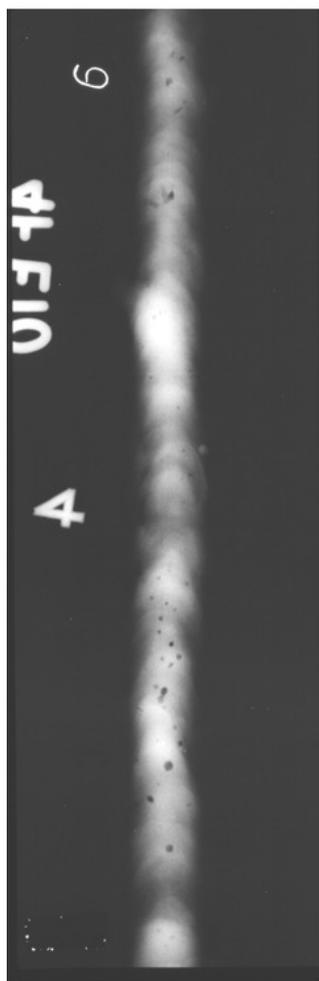


IIW/IIS  
Commission V  
Nº novo\_2\_106  
Type of  
Discontinuity:  
Grietas

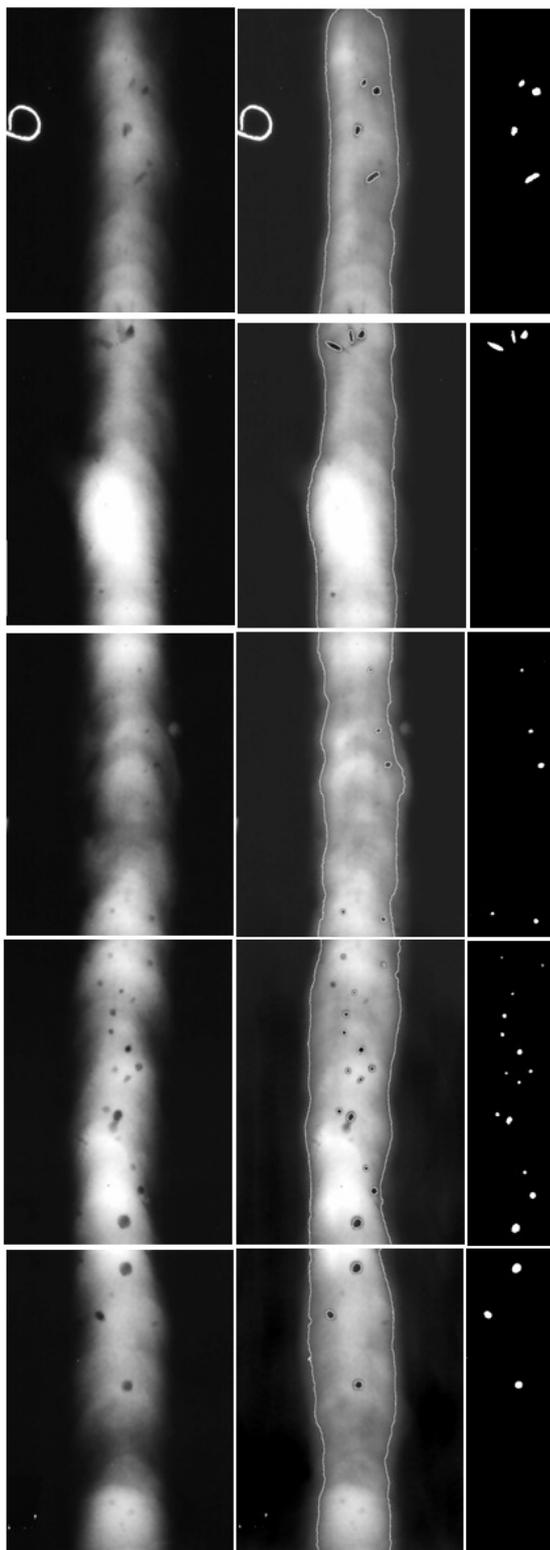


IIW/IS  
Commission V  
N° novo\_2\_64  
Type of  
Discontinuity:  
Grietas

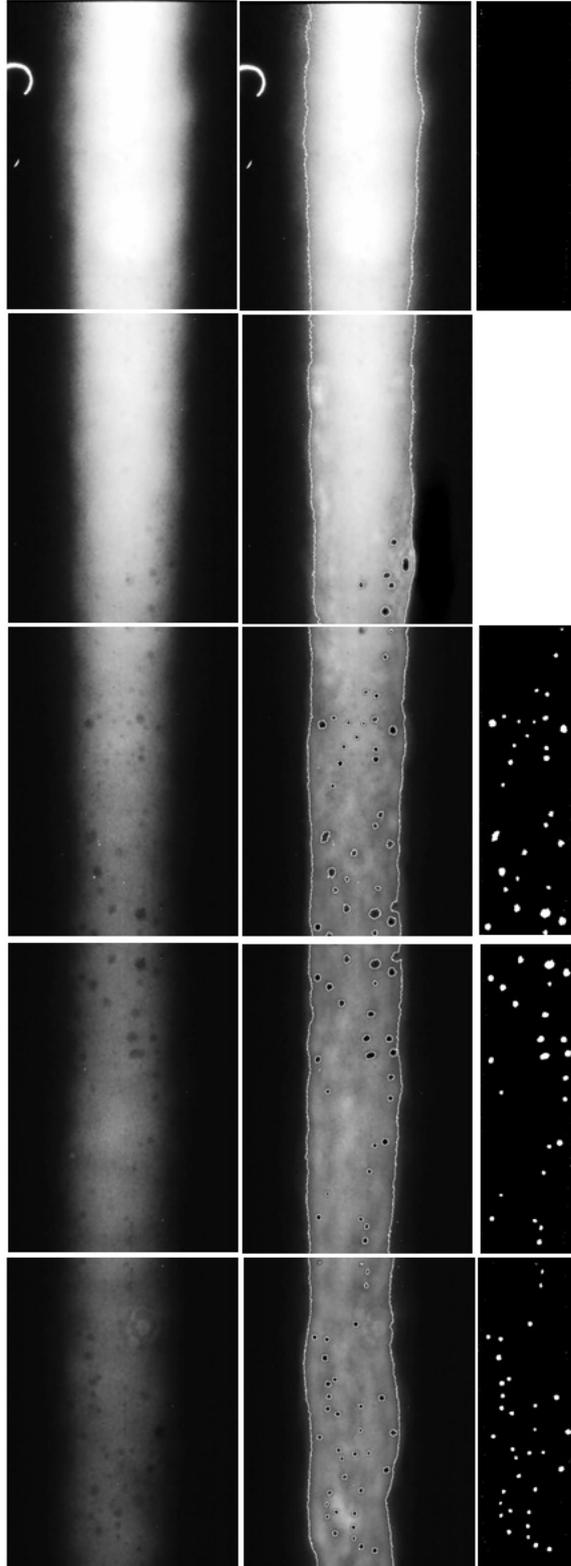
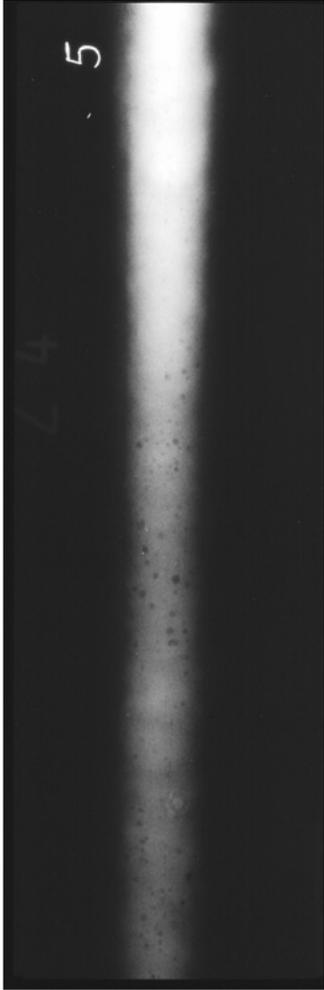


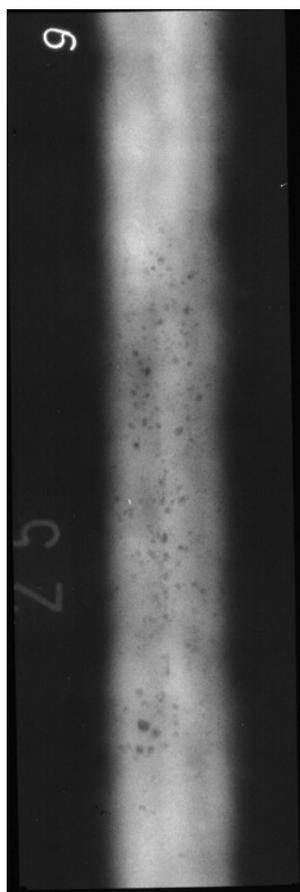


IIW/IS  
 Commission V  
 N° novo\_2\_06  
 Type of  
 Discontinuity:  
 Poros

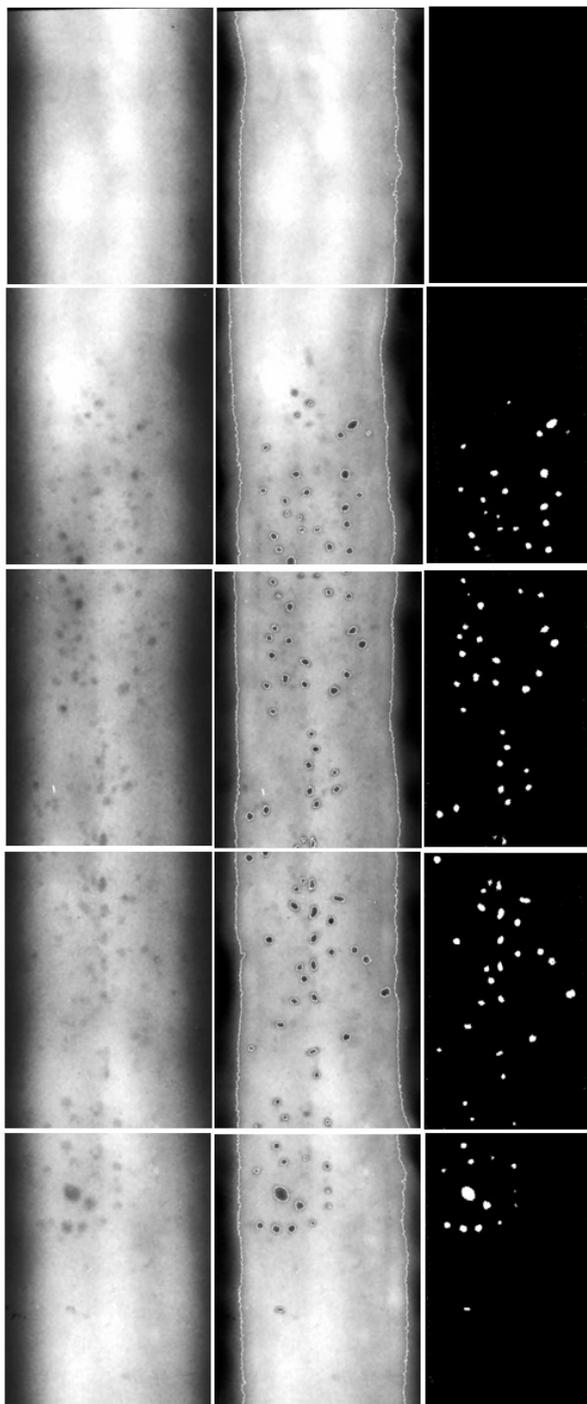


IIW/IIS  
Commission V  
N° novo\_2\_05  
Type of  
Discontinuity:  
Poros

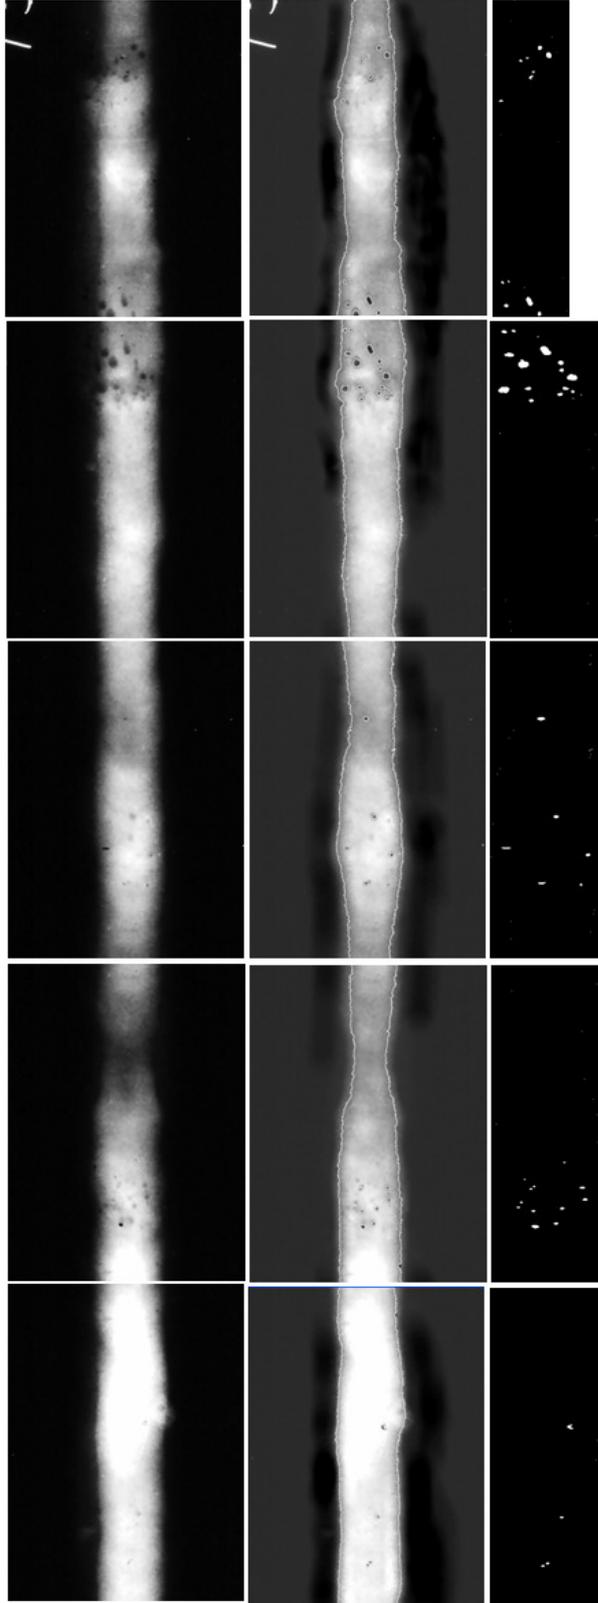
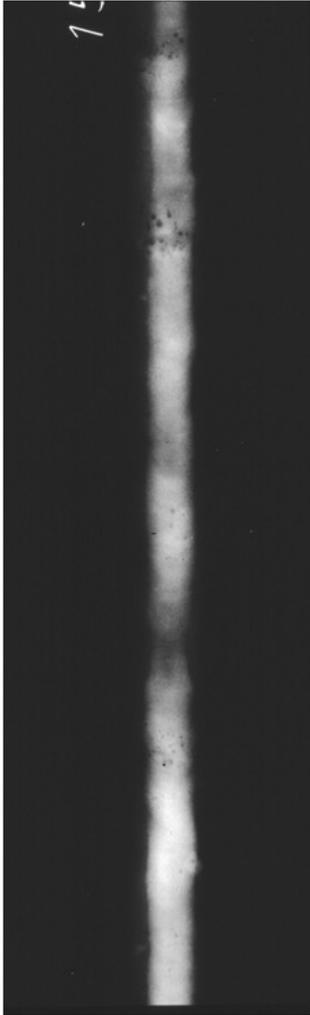


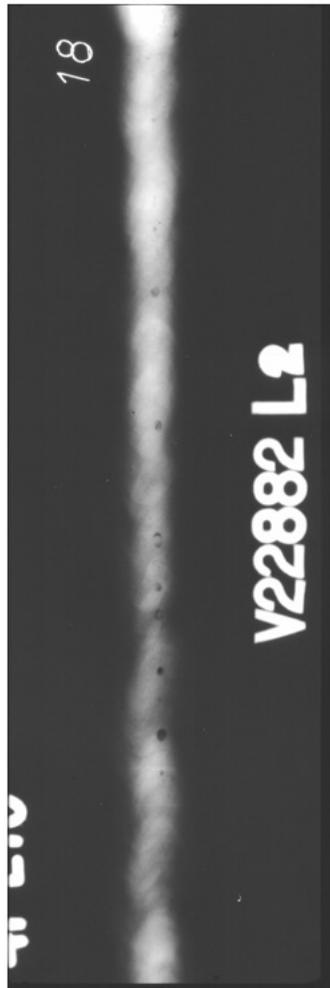


IIW/IS  
Commission V  
Nº novo\_2\_09  
Type of  
Discontinuity:  
Poros

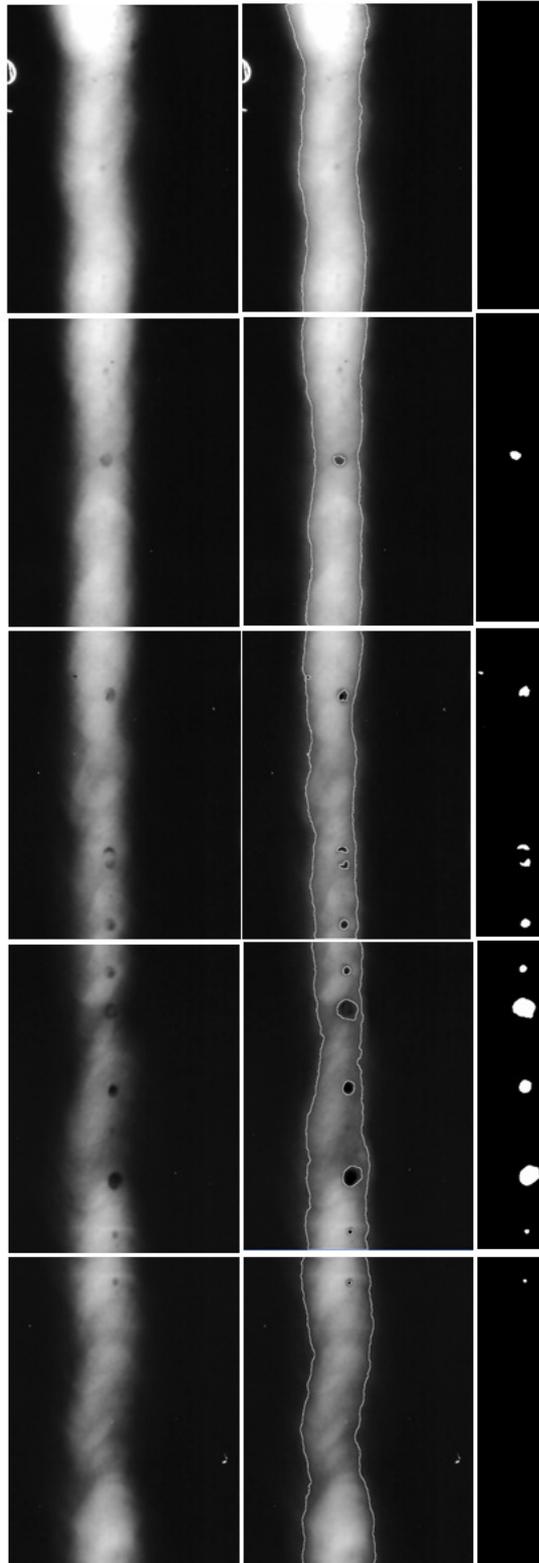


IIW/IIIS  
Commission V  
N° novo\_2\_15  
Type of  
Discontinuity:  
Poros

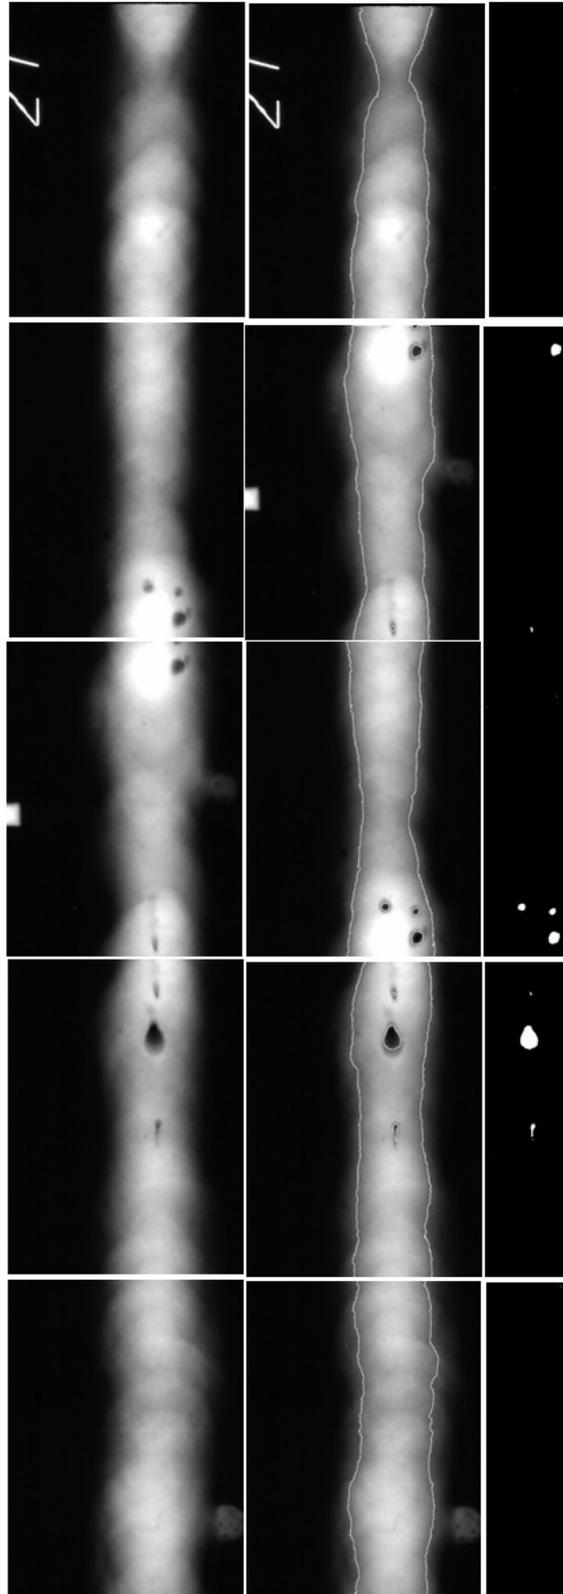
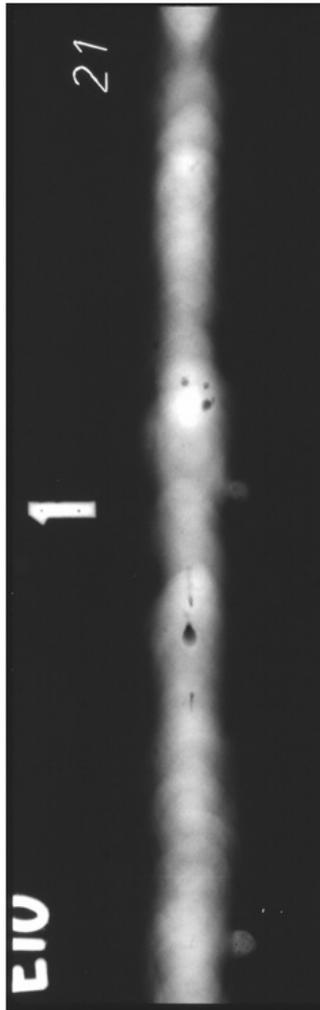




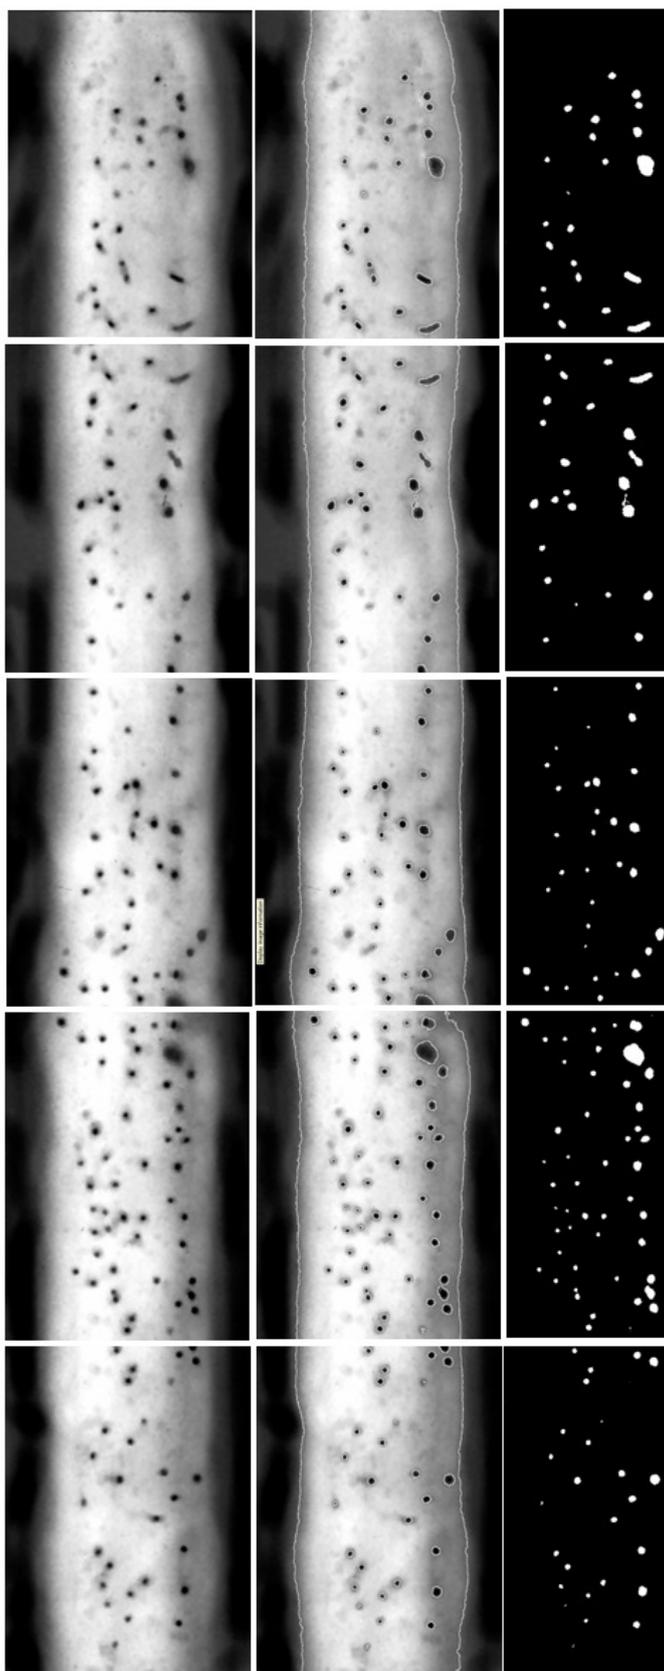
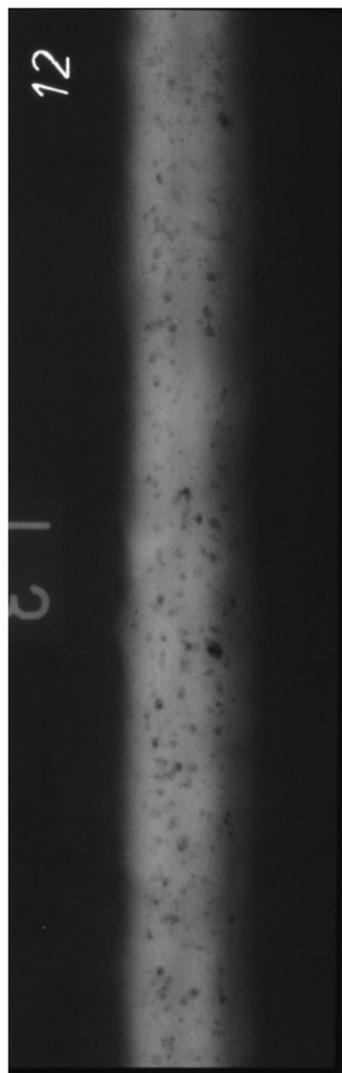
IIW/IS  
Commission V  
Nº novo\_2\_18  
Type of  
Discontinuity:  
Poros



IIW/IIS  
Commission V  
N° novo\_2\_21  
Type of  
Discontinuity:  
Poros



IIW/IS  
Commission V  
Nº novo\_2\_12  
Type of  
Discontinuity:  
Poros



---

## Bibliografía

---

- [1] <http://www.umax.com>, 2010.
- [2] Alaknanda, R. S. Anand, and Pradeep Kurma. Flaw detection in radiographic weldment images using morphological watershed segmentation technique. *NDT & E International*, 42(2-8):154–159, 2009.
- [3] L. Aoki and Y. Suga. Intelligent image processing for abstraction and discrimination of defect image in radiographic film. In *Proceeding of the Seventh International Offshore and Polar Engineering Conference, Honolulu*, volume 25, pages 527–531, May 1997.
- [4] L. Aoki and Y. Suga. Application of artificial neural network to discrimination of defect type in automatic radiographic testing of welds. *ISIJ Int*, 39(10):1081–1087, 1999.
- [5] ASME, Section 1. *American Society Mechanical Engineers*.
- [6] ASME V, ARTIGO III, Appendix II. *Digital Image Acquisition, Display, and Storage for Radiography and Radioscopy*.
- [7] J. C. Bezdec. Patter recognition with fuzzy objective function algorithms. *Plenum Press*, New York 1981.
- [8] M. A. Carrasco and D. Mery. Segmentation of welding defects using a robust algorithm. *Materials Evaluation*, 62(11):1142–1147, 2004.
- [9] M. J. Carreira. *Diagnóstico Asistido por Ordenador: Detección Automática de Nódulos Pulmonares*. PhD thesis, Universidad de Santiago de Compostela, 1996.
- [10] M. J. Carreira, D. Cabello, A. Mosquera, and M. G. Penedo. Integrating statistical and spatial information in medical image segmentation. In *Proceedings VI Mediterranean Conf. On Medical and Biological Engineering*, pages 517–520, 1992.
- [11] M. J. Carreira, D. Cabello, A. Mosquera, and M. G. Penedo. Progressive segmentation in medical images. In A.Y.J. Szeto and R.M Rangayyan, editors, *Proceedings 15th Annual International Conference IEEE Engineering and Biology Society*, volume 15, pages 152–153. IEEE, 1993.

- [12] K. R. Castleman. *Digital Image Processing*. Prentice-Hall, 1996.
- [13] J. L. Castro, M. Delgado, and C. J. Mantas. A fuzzy ruled-based algorithm to train perceptrons. *Fuzzy Sets and Systems*, 118:359–367, 2001.
- [14] Y. Cherfa, Y. Kabir, and R. Draï. X-rays image segmentation for ndt of welding defects. In *Proceedings of 7th European Conference on Non Destructive Testing*, volume 26, pages 2782–2789, 1998.
- [15] S. Chiu. Fuzzy model identification based on cluster estimation. *Journal of Intelligent and Fuzzy Systems*, 2(3), 1994.
- [16] R. R. da Silva, R. C. de Sa Brito, and A. A. Carvalho. Evaluation of the relevant features of welding defects in radiographic inspection. *Material Research*, 6(3):427–432, 2003.
- [17] R. R. da Silva and D. Mery. State of the art of weld seam inspection by radiographic testing: Part i-image processing. *Materials Evaluation*, 65(6):643–647, 2007.
- [18] R. R. da Silva and D. Mery. State of the art of weld seam inspection by radiographic testing: Part ii-pattern recognition. *Materials Evaluation*, 65(8):883–838, 2007.
- [19] R. R. da Silva, M. H. S. Siqueira, L. P. Calhoba, A. A. de Carvalho, and J. M. A. Rebello. Contribution to the development of a radiographic inspection automated system. In *8th European Conference on Non- Destructive Testing (ECNDT 2002)*, Barcelona, 17-21 June 2002. ECNDT 2002.
- [20] R. R. da Silva, M. H. S. Siqueira, L. P. Calhoba, and J. M. A. Rebello. Radiographic pattern recognition of welding defects using linear classifier. In *Insights*, volume 43, october 2001.
- [21] R. R. da Silva, M. H. S. Siqueira, L. P. Calhoba, and J. M. A. Rebello. Evaluation of the relevant characteristic parameters of welding defects and probability of correct classification using linear classifiers. *Insight*, 44(10), October 2002.
- [22] R. R. da Silva, M. H. S. Siqueira, L. P. Calhoba, and J. M. A. Rebello. Pattern recognition of weld defects detected by radiographic test. *NDT and E International*, 37(6):461–470, 2004.
- [23] R. R. da Silva, M. H. S. Siqueira, L. P. Calhoba, and J. M. A. Rebello. Estimated accuracy of classification of defects detected in welded joints by radiographic test. *NDT and E International*, 38(5):335–343, 2005.
- [24] W. Daum, P. Rose, H. Heidt, and J. H. Bultjes. Automatic recognition of weld defects in x-ray inspection. *Br J NDT*, 29(2):79–82, 1987.
- [25] J. E. Dennis and R. B. Schnabel. *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*. Prentice-Hall, 1983.

- 
- [26] G. R. Edward. Inspection of welded joints. In *ASM Handbook Welding, Brazing and Soldering*, volume 6, pages 1081–1088, Materials Park, Ohio, 1993. ASM International.
- [27] M. K. Felisberto, H. S. Lopes, T. M. Centeno, and L. V. Arruda. An object detection and recognition system for weld bead extraction from digital radiographs. *Computer Vision and Image Understanding*, 102(3):238–249, 2006.
- [28] F. D. Foresee and M. T. Hagan. Gauss-newton approximation to bayesian regularization. In *Proceedings of the 1997 International Joint Conference on Neural Networks*, pages 1930–1935, 1997.
- [29] F. Fucsok, C. Muller, and M. Scharmach. Reliability of routine radiographic film evaluation—an extended roc study of the human factor. In *8th European Conference on Non-Destructive Testing, Barcelona*, pages 17–21, 2002.
- [30] F. Fucsok and M. Scharmach. Human factors: The reliability of routine radiographic film evaluation. In *15th World Conference on Non-Destructive Testing, Rome*, pages 15–21, 2000.
- [31] A. Gayer, A. Saya, and A. Shiloh. Automatic recognition of welding defects in real-time radiography. *NDT & E International*, 23(3):131–136, 1990.
- [32] D. E. Goldberg. *Generic algorithms in search, optimization, and machine learning*. Reading MA: Addison Wesley, 1989.
- [33] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Addison-Wesley Publishing Company, 1992.
- [34] M. M. Gupta and D. H. Rao. On the principles of fuzzy neural networks. *Fuzzy Sets and Systems*, 61:1–18, 1994.
- [35] Koshimizu H. and T. Yoshida. A method for visual inspection of welding by means of image processing of x-ray photograph. *Trans. of IECE of Japan*, E-66(11):641–648, 1983.
- [36] M. T. Hagan and M. Menhaj. Training feed-forward networks with the marquardt algorithm. *IEEE Transaction on Neural Networks*, 5(6):989–993, 1994.
- [37] R. M. Haralick and L. Shapiro. *Computer and Robot Vision, Vol 1*, pages 28–48. Addison Wesley, 1992.
- [38] A. Ishii, V. Lashkia, and Y. Ochi. An image processing algorithm for small defect detection. *Japanese Journal of SNDI*, 42(4):199–205, 1993.
- [39] A. Ishii, V. Lashkia, Y. Ochi, and M. Akutsu. Recognition of internal weld defects by defect model. *Transaction of the Japan Society of Mechanical Engineers*, 60(578):2440–2445, 1994.
- [40] C. Jacobsen, C. Nockemann, and U. Zscherpel. Crack detection in digitized radiographs with neural methods. In *Proceedings of 7th European Conference on Non Destructive Testing*, pages 2717–2724, Copenhagen, Mayo 1998.

- [41] A. K. Jain and Y. Dubuisson. Segmentation of x-ray and c-scan images of fiber reinforced composite materials. *Pattern Recognition*, 25(3):257–270, 1992.
- [42] J. R. Jang. Anfis: adaptive-network-based fuzzy inference system. *IEEE Trans. Syst., Man, Cybern.*, 23(3):665–685, 1993.
- [43] Y. Kato, T. Okumura, K. Itoga, T. Harada, K. Sugimoto, K. Michiba, and S. Iuchi. Development of the automatic system for radiographic film interpretation. *Japanese Journal of SNDI*, 4:196–206, 1992.
- [44] A. Kehoe and G. A. Parker. Image processing for industrial radiographic inspection: Image enhancement. *British Journal of NDT*, 32(4):183–190, 1990.
- [45] V. Lashkia. Defect detection in x-ray images using fuzzy reasoning. *Image and Vision Computing*, 19:261–269, 2001.
- [46] M. Laviolette and J. W. Seaman. The efficacy of fuzzy representations of uncertainty. *IEEE Transactions on Fuzzy Systems*, 2(1), 1994.
- [47] S. W. Lawson and G. A. Parker. Intelligent segmentation of industrial radiographic images using neural networks. *SPIE*, 2347:245–255, 1994.
- [48] D. Li and T. W. Liao. Applications of fuzzy k-nn in weld recognition and tool failure monitoring. In *Proceedings of the Twenty-Eighth Southeastern Symposium*, pages 222–226, March–April 1996.
- [49] Y. Li and T. W. Liao. Weld defect detection based on gaussian curve. In *Proceedings of the 28th Southeastern Symposium on System Theorie*, pages 227–231, 1996.
- [50] D. Liang, W. Zhen, G. Zhang, L. Qi, Y. Tong, and Y. Y.Hu. Automatical identification of the defect level of welding seam based on x-ray image. In *Proceedings of International Symposium on Nondestructive Testing and Stress-Strain Measurement*, pages 267–274, Tokyo, 1992.
- [51] T. W. Liao. Classification of welding flaw types with fuzzy expert systems. *Expert Systems with Applications*, 25:101–111, 2003.
- [52] T. W. Liao. Fuzzy reasoning based automatic inspection of radiographic welds: Welds recognition. *Journal of Intelligent Manufacturing*, 15(1):69–85, February 2004.
- [53] T. W. Liao, D. M. Li, and Y. M. Li. Detection of welding flaws from radiographic images with fuzzy clustering methods. *Fuzzy Sets Syst.*, 108(2):145–158, 1999.
- [54] T. W. Liao, D. M. Li, and Y. M. Li. Extraction of welds from radiographic images using fuzzy classifiers. *Inform. Sci.*, 126:21–42, 2000.
- [55] T. W. Liao and Y. M. Li. An automated radiographic ndt system for weld inspection. part II. flaw detection. *NDT & E International*, 31(3):183–192, 1998.

- 
- [56] T. W. Liao and J. Ni. An automated radiographic ndt system for weld inspection. part I. weld extraction. *NDT & E International*, 29(3):157–162, 1996.
- [57] T. W. Liao and K. Tang. Automated extraction of welds from digitized radiographic images based on mlp neural networks. *Applications of Artificial Intelligence*, 11:197–218, 1997.
- [58] J. S. Lim. *Two-Dimensional Signal and Image Processing*, pages 536–540. Prentice Hall, Englewood Cliffs, NJ,, 1990.
- [59] T. Y. Lim, M. M. Ratnam, and M. A. Khalid. Automatic classification of weld defects using simulated data and an mlp neural network. *Insight: Non-Destructive Testing and Condition Monitoring*, 49(3):154–159, March 2007.
- [60] D. Linkens and J. Nie. *Fuzzy Neural Control. Principles, Algorithms and Applications*. Prentice Hall, 1995.
- [61] D. J. C. MacKay. Bayesian interpolation. *Neural Computation*, 4(3):415–447, 1992.
- [62] V. Y. Maklashevsky, V.N. Filinov, and M. V. Filinov. Digital processing of roentgenographic and x-ray television image in aerorpace radiographic testing. In *Proceedings of 7th European Conference on Non Destructive Testing Copenhagen*, volume 26, pages 326–333, May 1998.
- [63] E. H. Mamdani and S. Assilian. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 1975.
- [64] W. J. McGonnagle. Quality control and nondestructive testing in reactor pressure vessel fabrication. *Nuclear Engineering and Desing*, 2(3):293–300, 1965.
- [65] R. Merenyi and W. G. Heller. Video data enhancement for nondestructive evaluation. In *Review of Progress in Quantitative Nondestructive Evaluation*, pages 705–712, 1988.
- [66] D. Mery and M. Berti. Automatic detection of welding defects using texture features. In *International Symposium on Computed Tomography and Image Processing for Industrial Radiology*, Berlin, June 2003.
- [67] D. Mery, R. R. da Silva, L. P. Caloba, and J. M. A. Rebello. Pettern recognition in the automatic inspection of aluminium casting. *Insight, Journal of the British Institute of Non-destructive Testing*, 45(7):441–449, 2003.
- [68] A. Mosquera, D. Cabello, M. J. Carreira, and M. G. Penedo. Unsupervised textured image segmentation using markov random field and clustering algorithms. *Computer Analysis of Images and Patterns. Research in Informatics*, 5, 1991.
- [69] K. Murakami. Image processing for non-destructive testing. *Weld. Int.*, 4(2):144–149, 1990.

- [70] K. Murakami. Image processing for non-destructive testing. *Welding International*, 4(2):144–149, 1998.
- [71] R. Murakami. Detection and classification of welding defects in the x-ray films by using image processing and neural network. In *IAPR QCAV 98*, pages 480–484, 1998.
- [72] N. Nacereddine and D. Redouane. Weld defect extraction and classification in radiographic testing based artificial neural networks. In *Proceedings of 15th World Conference on Non Destructive Testing*, Roma, October 2000.
- [73] N. Nacereddine and M. Tridi. Computed-aided shape analysis and classification of weld defects in industrial radiography based invariant attributes and neural networks. In *Proceedings of the 4th International Symposium on Image Signal Processing and Analysis*, 2005.
- [74] N. Nacereddine, M. Tridi, L. Hamami, and D. Ziou. Statistical tools for weld evaluation in radiographic testing. In *ECNDT 2006*, 2006.
- [75] N. Nacereddine, M. Zelmat, S. S. Belaifa, and M. Trini. Weld defect detection in industrial radiographic based digital image processing. In *Proceedings of International Conference on Signal Processing, ICSP2004*, Istambul, Turkey, Dec. 2004.
- [76] H. Narazaki and A. L. Ralescu. An improved synthesis method for multilayered neural networks using qualitative knowledge. *IEEE Transactions on Fuzzy Systems*, 1(2):125–137, 1993.
- [77] D. Nguyen and B. Widrow. Improving the learning speed of 2-layer neural network by choosing initial values of the adaptive weights. In *Proceedings of the International Joint Conference on Neural Networks*, volume 3, pages 21–26, 1990.
- [78] W. Niblack. *Introduction to digital image processing*. Prentice Hall, 1986.
- [79] H. Ogawa, E. Oja, and J. Wangviwattana. Principal component analysis by homogeneous neural networks, part II: Analysis and extensions of the learning algorithms. *IEICE Trans. Inf. and Systems*, E75-D(3):376–382, May 1992.
- [80] E. Oja, H. Ogawa, and J. Wangviwattana. Principal component analysis by homogeneous neural networks, part I: The weighted subspace criterion. *IEICE Trans. Inf. and Systems*, E75-D(3):366–375, May 1992.
- [81] N. Otsu. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1):62–66, 1979.
- [82] G. X. Padua, R. R. Silva, L. P. Calba, and M. H. S. Siqueira. Classification of welding defects in radiographs using transversal profiles to the weld seam. In *16th World Conference on Nondestructive Testing*, Montreal, August 30 2004.

- 
- [83] P. Perner and S. Trautzsch. On feature partitioning for decision tree induction. In *Proceedings of SSPR98 and SPR98*, pages 475–482, Copenhagen, Mayo 1998.
- [84] P. Perner, U. Zscherpel, and C. Jacobsen. A comparison between neural networks and decision trees based on data from industrial radiographic testing. *Pattern Recognition Letters*, 22:47–54, 2001.
- [85] J. R. Quinlain. Induction of decision trees. *Machine Learning*, 1:81–106, 1996.
- [86] P. K. Sahoo. A survey of thresholding techniques. *Computer Vision, Graphics and Image Processing*, 41(2):233–260, February 1988.
- [87] J. M. Seixas, L. P. Caloba, and I. Delpino. Relevance criteria for variance detection in classifier designs. In *International Conference on Engineering Applications of Neural Networks*, 1996.
- [88] H. I. Shafeek, E. S. Gadelmawala, A. A. Abbel-Shafy, and I. W. Elewa. Assessment of welding defects for gas pipeline radiographs user computing vision. *NDT & E International*, 37(4):291–299, 2004.
- [89] H. I. Shafeek, E. S. Gadelmawala, A. A. Abbel-Shafy, and I. W. Elewa. Automatic inspection of gas pipeline welding defects using an expert vision system. *NDT & E International*, 37(4):301–307, 2004.
- [90] S. Shemlon, S. M. Dunn, and T. Liang. Progressive knowledge use in incremental segmentation. In *Proceedings of the SPIE International Society for Optical Engineering*, volume 1095, pages 239–250, 1989.
- [91] S. Shemlon, S. M. Dunn, and T. Liang. Progressive knowledge use in incremental segmentation. In *Proceedings of the SPIE*, volume 1095, pages 239–250, 1989.
- [92] Y. Shirai. Automatic inspection of x-ray photograph of welding. *Pattern Recognition*, pages 257–261, 1967.
- [93] Y. Suga, K. Kojima, and T. Tominaga. Detection of weld defects by computer aided x-ray radiography image processing. *International Journal of Offshore and Polar Engineering*, 5(2):142–146, 1995.
- [94] T. Takagi and M. Sugeno. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics*, 15:116–132, 1985.
- [95] R. Vilar, J. Zapata, L. Bernabé, and R. Ruiz. Automatic recognition of weld regions in radiographic images of welded joints. In *Proceedings of the IASTED International Conference, Visualization, Imaging, and Image Processing*, pages 538–544, Marbella, Spain, 2001. IASTED, Acta Press.
- [96] R. Vilar, J. Zapata, and J. Ruiz. Técnicas de reconocimiento automático de cordones de soldadura en radiografías de uniones soldadas. In *Proceedings III Congreso Iberoamericano de Ingeniería Mecánica*, La Habana, Cuba, 1997.

- [97] R. Vilar, J. Zapata, and R. Ruiz. Automatic recognition of weld regions in radiographic images of welded joints. In *Proceedings of the TELECOM2001 and JFMMA*, pages 470–475, Casablanca, Octubre 2001. Actes du Colloque.
- [98] R. Vilar, J. Zapata, and R. Ruiz. Weld defects recognition and classification based on ann. In *Proceedings of the Fifth IASTED International Conference on Signal Processing, Pattern Recognition, and Application*, Innsbruck, Austria, February 2008. IASTED.
- [99] R. Vilar, J. Zapata, and R. Ruiz. An automatic system of classification of weld defects in radiographic images. *NDT & E International*, 42(5):467–476, July 2009.
- [100] R. Vilar, J. Zapata, and R. Ruiz. Classification of welding defects in radiographic images using an ann with modified performance function. In *Proceedings of the third International Work-Conference of the Interplay Between Natural and Artificial Computation, IWINAC 2009*, Santiago de Compostela, Spain, June 2009. IWINAC 2009.
- [101] R. Vilar, J. Zapata, R. Ruiz, and I. Villo. Automatic detection of weld defects in radiographic images. In *Proceedings of the 5th Edition of International Conference of the Faculty of Electrical Engineering, FIE08*, Santiago de Cuba, Cuba, July 2008. FIE08.
- [102] G. Wang and T. W. Liao. Automatic identification of different types of welding defects in radiographic images. *NDT & E International*, 35:519–528, 2002.
- [103] L. X. Wang and J. M. Mendel. Generating fuzzy rules by learning from examples. *IEEE Transaction on System, Man, and Cybernetics*, 22(6):1414–1427, 1992.
- [104] S. Watanabe. *Pattern Recognition: Human and Mechanical*. Wiley, New York, 1985.
- [105] K. L. Wen, L. J. Liang, and C. S. Shing. Computer aided x-ray radiographic image processing inspection for welding. In *Proceedings of the Third International Offshore and Polar Engineering Conference*, pages 462–466, Singapore, June 6-11 1993.
- [106] R. Wilson and M. Spann. Image segmentation and uncertainty. *Research Studies Press Ltd*, 1988.
- [107] L. Yue, L. Xiaohong, and R. Dahau. Computer vision application for weld defect detection and evaluation. In *Proceeding of the 1998 Conference on Automated Optical Engineering*, pages 355–354, Bellingham, WA, USA, 1998.
- [108] J. Zapata, R. Ruiz, and R. Vilar. An automatic welding defects classifier system. In *Proceedings of the III International Conference on Computer Vision Theory and Applications*, Funchal, Madeira - Portugal, January 2008. VISAPP.

- [109] J. Zapata, R. Vilar, and R. Ruiz. An adaptive-network based fuzzy inference system for classification of welding defects. *NDT & E International*, 43(Issue 3):191–199, April 2010.
- [110] U. Zscherpel. Film digitisation systems for dir: Standards, requirements, archiving and printing. 5 (05), NDT.net (<http://www.ndt.net>), May 2000.
- [111] U. Zscherpel. A new computer based concept for digital radiographic reference images. 7 (12), NDT.net (<http://www.ndt.net>), November 2002.



---

## Índice alfabético

---

- Algoritmo de clusterización, 119
- Algoritmo de Levenberg-Marquardt, 164
- Algoritmo de retropropagación del gradiente (backpropagation), 73
- Algoritmo de seguimiento de contornos, 123
- Algoritmo Least Minimum Squares, 73
- Algoritmo surface-fitting, 39
- Análisis de componentes principales, 155
  
- Backpropagation/Retropropagación, 68
  
- Cadenas de Markov, 80
- Canny, 33
- Clasificador borroso c-means, 31
- Clasificador borroso k-nearest neighbour (K-NN), 31
- Codificación de vértices, 122
- Contraste radiográfico, 2
- Control bottom-up, 116
- Control híbrido retroalimentado, 117
- Control jerárquico, 116
- Control top-down, 117
  
- Definición radiográfica, 3
- Densidad radiográfica, 5
- Deriche, 33
- Distancia city-block, 119
  
- Early stopping, 167
- Ecualización del histograma, 28
- Efecto ringing, 104
- Etiquetado de componentes conectados, 111
  
- Filtro adaptativo Wiener, 99
- Filtro Bessel, 35
- Filtro bottom-hat, 34
  
- Filtro Bridge, 33
- Filtro Gaussiano, 99
- Filtro Kirsch, 33
- Filtro mediana, 28
- Filtro Savitzky-Golay, 35
- Filtro smoothing, 33
- Función Better, 126
  
- Indicador de Calidad de la Imagen (ICI), 6
- inicialización de Nguyen-Widrow, 163
  
- Limado de contornos, 122
  
- Método cuasi-Newton, 164
- Método de Newton, 163
- Método Mamdani, 88
- Método Otsu, 133
- Matriz de covarianzas, 148
- Modelo Sugeni, 89
- Modelo TSK, 89
  
- Perceptrón multicapa, 70
- Prewitt, 33
  
- Reconocimiento de patrones, 57
- Redes Bayesianas, 80
- Regla Delta, 73
- Regularización Bayesiana, 167
- Regularización con función de rendimiento modificada, 166
  
- Segmentación basada en perfiles, 111
- Segmentación progresiva, 111
- Seguimiento de contornos, 122
- Slicing zonal, 115
  
- Técnica de Fletcher-Reeves, 31
- Teoría de Dempster-Shafer, 78

Transformada Watershed, 34

Wilson y Spann, 119