

TESIS DOCTORAL

**ARQUITECTURA DINÁMICA PARA INSPECCIÓN VISUAL  
DE SUPERFICIES EN TIEMPO-REAL**

**David Martín Gómez**

Licenciado en Ciencias Físicas por la  
Universidad Nacional de Educación a Distancia

DEPARTAMENTO DE INTELIGENCIA ARTIFICIAL  
ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA INFORMÁTICA  
UNIVERSIDAD NACIONAL DE EDUCACIÓN A DISTANCIA

Madrid, 2007



**Departamento de Inteligencia Artificial**

**Escuela Técnica Superior de Ingeniería Informática**

**ARQUITECTURA DINÁMICA PARA INSPECCIÓN VISUAL  
DE SUPERFICIES EN TIEMPO-REAL**

**David Martín Gómez**

Licenciado en Ciencias Físicas por la  
Universidad Nacional de Educación a Distancia

Director:

**Dr. D. Domingo Guinea Díaz (IAI-CSIC)**

Codirector:

**Dr. D. Mariano Rincón Zamorano (UNED)**

Madrid, 2007



## *Agradecimientos*

En primer lugar deseo mostrar mi más sincero agradecimiento a mi director de tesis Dr. Domingo Guinea Díaz, y a mi profesor y codirector, Dr. Mariano Rincón Zamorano, por su labor de dirección y su ayuda en la realización de esta tesis, que a lo largo de estos cinco años han motivado mi labor investigadora. A la Dra. Maria C. García-Alegre por su apoyo y ayuda constante desde el principio y a la Dra. Ángela Ribeiro por su interés continuo en mi trabajo. Al ingeniero Eugenio Villanueva por su ayuda interminable, sus consejos prácticos y su saber hacer, que siempre me han ayudado a solucionar los problemas técnicos y me han aportado muchos conocimientos útiles.

Agradezco también la financiación del proyecto ACERINOX “Sistema de Detección Visual y Clasificación de Cascarilla Residual en Laminados de Acero Inoxidable” que ha permitido mantenerme durante estos años y del cual Domingo Guinea fue investigador principal, y cuyo marco origino el inicio de esta tesis doctoral. Como no, en este mismo contexto agradecer a las empresas Acerinox S.A., TCC S.A. y Anafocus su predisposición y apuesta por la investigación, que siempre han facilitado nuestro trabajo aportando todos los medios disponibles a su alcance. Esto ha sido posible gracias al equipo de doctores e ingenieros de las entidades participantes en el proyecto, IAI (CSIC), Universidad de Málaga y IMSE-CNM (CSIC) y, en especial, a los doctores Carlos Spinola y Servando Espejo, y a los ingenieros Sergio Morillas y Juan José Carmona. Además, las visitas a Acerinox siempre fueron un referente para mi trabajo, desde la puesta en marcha de los sistemas de inspección en la propia línea de producción hasta las conversaciones con los inspectores de línea y operarios que me ayudaron a comprender la labor diaria de inspección; y las charlas con Domingo y Eugenio en los viajes al Campo de Gibraltar donde se encuentra ubicada una de las fabricas de Acerinox, donde siempre comentábamos con ilusión los detalles de las reuniones y pruebas, y a la vuelta los trabajos y objetivos que teníamos que cumplir.

El Instituto de Automática Industrial (IAI) del CSIC ha sido mi principal lugar de trabajo, y quiero dar las gracias a toda su gente. En especial, al director del centro Dr. Salvador Ros le agradezco todos los medios que han estado a mi disposición y la confianza que deposito en mí desde el principio, al personal del taller de electrónica y mecánico que siempre me han ayudado en tantas y tan variadas tareas, gracias por vuestra comprensión y paciencia; gracias también al personal de administración y al de servicios generales.

Pero sin lugar a dudas, agradecer el día a día con mucha gente en el IAI, en especial, con los miembros del departamento de Sistemas de la segunda planta del edificio B que siempre han estado pendientes de mi trabajo: Teresa, Carlos, Montse, José Javier, Eugenio, Luís, Ángela, Maria, Domingo y Alberto; con todos mis compañeros y amigos que tantos momentos buenos hemos compartido y siempre me han apoyado y animado: Juan Carlos, David, Dani, Lía, Jesús, Javi, Xavi, Carlos Julián, Oscar, Roberto, Marta, Juan, Nacho, Patricia, Miguel, José, Jorge, Marga, Manuel, Ricardo, Bea, Rodrigo, Almudena, Luís, Disney, Domingo Miguel y Roberto; y con los compañeros y amigos del grupo de pilas de combustible: Gonzalo, Leandro, Carras, Fran, Javi, Lorena, Juanma, Carlos, Alberto, Omar, Victor, Miguel Ángel, Wilton, Dani, y las compañeras del ICV, Berta, Miriam y Eva.

De modo muy especial quiero agradecer a mi compañera y amiga la Dra. Lía García Pérez su apoyo y ayuda en todas las etapas de la tesis, y que haya leído con mucho cuidado y paciencia el borrador de la primera parte de esta tesis y corregido con entendimiento.

La UNED ha sido también mi lugar de trabajo y quiero agradecer el trato cercano que siempre he recibido de los profesores del departamento de Inteligencia Artificial, y en especial, de la profesora Margarita Bachiller y los profesores Rafael Martínez, Francisco Javier Díez y José Ramón Álvarez Sánchez, que siempre se han interesado por mi trabajo en el periodo de docencia e investigación y en la evolución de mi tesis.

La última etapa de trabajo ha estado marcada por mi estancia en el CERN, y quiero agradecer a los ingenieros Herve Milcent y Enrique Blanco su apoyo en la finalización de esta tesis, su conocimiento y sus formas de hacer las cosas que me han aportado nuevas ideas y un enorme aprendizaje, y a los compañeros y amigos que durante este último año me han apoyado y animado constantemente, Clara, Manu, Pablo, Edu, Sandro, Alexander, Barbara, Solveig, Odd, Laura, Tonje y John.

Y a mis amigos de toda la vida, que siempre me han animado a trabajar en la tesis y han entendido mis ausencias, Rubén, Héctor, Paco, Patri, Fran, Natalia, Juanan, Elena, Iván, Quique, Diego, Raquel y mis amigos de la UNED, Rubén, Santa, Fernando, Alberto, David, Maku, Miguel, Marta, Chechu, Anita, gracias a todos. Y a Lucia que siempre me ha animado continuamente.

Y finalmente quiero agradecer a toda mi familia su paciencia y apoyo que me han proporcionado siempre, en especial, a mis padres Patri y José Luís y a mi hermano José a los que dedico la tesis por su paciencia y su cuidadosa y esmerada dedicación en todas las facetas de mí vida que me han aportado todo.



## Resumen

### *Los sistemas de visión artificial en la automatización de la inspección visual*

Los sistemas de visión artificial proporcionan soluciones innovadoras en el ámbito de la automatización industrial, que mejoran considerablemente la gestión de la productividad y la calidad de los productos manufacturados aumentando su competitividad en el mercado. Un gran número de actividades industriales se han beneficiado de la utilización de las tecnologías de visión artificial en las áreas textil, del metal, manufacturado de cristal, componentes de maquinaria, piedra tallada, circuitos integrados, entre otras. La mayoría de los sistemas automáticos de visión artificial han sido diseñados para una aplicación específica totalmente caracterizada, careciendo de la flexibilidad necesaria para su utilización en otros dominios de aplicación.

### *El objetivo de la tesis*

El objetivo principal de esta tesis ha sido el diseño y desarrollo de una Arquitectura Dinámica para Inspección Visual de Superficies en Tiempo-Real que posee las propiedades de flexibilidad, reconfigurabilidad y viabilidad requeridas para su utilización en un conjunto amplio de aplicaciones.

### *La arquitectura propuesta*

La arquitectura se ha planteado desde la perspectiva del conocimiento acotado de una imagen superficial, en una arquitectura jerárquica de tres niveles: tareas, métodos y conocimiento del dominio; que permite, entre otros, la definición de componentes genéricos para su reutilización en diversas tareas de inspección visual de superficies. Por ello, a partir de la definición precisa y concisa del problema, se ha modelado la solución siguiendo la metodología de CommonKADS (Common Knowledge Analysis and Documentation System o Common Knowledge Analysis and Design Support, entre otras). Las tareas más relevantes han sido:

1. Configuración del sistema para adaptarse al tipo de material y defectos superficiales propios, al entorno, y a la operación a realizar en tiempo real.
2. Detección, clasificación e interpretación de defectos superficiales.
3. Diagnóstico de calidad del material inspeccionado.

A partir de estas tareas se han planteado los PSMs (Métodos de Solución de Problemas (en inglés, Problem Solving Methods)) adecuados para la resolución de las tareas de inspección de varios materiales o procesos. El modelado del conocimiento del dominio engloba la adquisición de conocimiento para la caracterización de los defectos sobre diferentes soportes: metal, papel, plástico, textil y madera. Estas etapas se enriquecen con el conocimiento genérico propio de las técnicas, métodos y procedimientos de visión artificial apropiados para inspección de defectos superficiales.

*La aplicación (o dominio seleccionado)*

Con el propósito de acotar el problema, y aumentar la robustez y la fiabilidad de la solución; el sistema se centra en la inspección de superficies de materiales laminados. En particular, en la resolución de un tipo de problema: los defectos de puntos de óxido de los laminados de acero inoxidable (cascarilla residual). La consecución de los objetivos de análisis y diseño de la aplicación se basan en el estudio exhaustivo de cada una de las tareas a resolver por el sistema y de los métodos de resolución de las tareas; utilizando todo el conocimiento del dominio disponible.

*Recursos experimentales*

Desde el punto de vista de los sistemas físicos, la complejidad física asociada a los dispositivos clásicos de inspección visual, se ha resuelto con la integración de iluminación láser de baja potencia. Esta investigación, de carácter innovador, es una solución viable y robusta al problema de la iluminación en entornos industriales estructurados.

En concreto se ha diseñado, desarrollado y probado los siguientes métodos:

- Formación de imagen visual con iluminación estándar.
- Formación de imagen con iluminación láser coaxial.
- Formación de imagen con iluminación láser exterior incidiendo con ángulos de  $30^\circ$  a  $45^\circ$  respecto al eje óptico de la cámara.

Con el objetivo de seleccionar el mejor sistema para inspección superficial de este tipo de materiales y contrastar el método anteriormente propuesto, se han realizado pruebas con:

- Sensor fotoeléctrico.
- Espectroscopia óptica de emisión resuelta en tiempo y espacio.
- Cámaras convencionales con iluminación estándar.

#### *Comentarios finales*

Se concluye que la integración de modelos de inteligencia artificial, en las tareas de inspección con sistemas de visión artificial, ha permitido disponer de una arquitectura jerárquica adaptable a diversos dominios de inspección, para la resolución de un tipo de problemas. Los objetivos multidisciplinares propuestos para la resolución del problema de inspección superficial, han conducido a obtener una solución con las características deseadas de flexibilidad, reconfigurabilidad y viabilidad, optimizada en este caso para una aplicación concreta: la inspección industrial de microdefectos en laminados de acero inoxidable en tiempo real.



# Índice general

<b>I Estado del Arte y Métodos Experimentales para la Inspección de Superficies</b>	<b>35</b>
<b>1. Sistemas de inspección visual industrial</b>	<b>37</b>
1.1. Visión por computador (“Computer Vision”) . . . . .	38
1.2. Visión industrial por computador (“Machine Vision”) . . . . .	39
1.3. Inspección visual manual . . . . .	41
1.4. Sistemas de visión industrial . . . . .	43
1.4.1. Etapas en un sistema de visión industrial . . . . .	51
1.4.2. Aplicaciones de inspección con sistemas de visión industrial . . . . .	56
1.5. Inspección Industrial de superficies . . . . .	58
<b>2. Arquitecturas para inspección visual industrial en tiempo-real</b>	<b>63</b>
2.1. Arquitecturas de visión dinámicas y reconfigurables . . . . .	70
2.2. Inspección visual automática . . . . .	77
2.2.1. Requisitos generales de un sistema de inspección visual automático . . . . .	82
2.3. Arquitecturas cognitivas en tiempo-real . . . . .	84
<b>3. Detección de defectos superficiales de oxido en acero inoxidable en tiempo-real</b>	<b>89</b>
3.1. Conceptos sobre acero inoxidable y oxido de hierro (cascarilla residual)	90
3.2. Descripción de cascarilla residual en el nivel del conocimiento (lenguaje natural) . . . . .	91
3.3. Estudio espectro-fotométrico de óxido de hierro frente a acero inoxidable base . . . . .	94

3.3.1.	Curvas espectrales de seis muestras de acero inoxidable frente a óxido . . . . .	94
3.3.2.	Estadísticas punto a punto (media y desviación estándar) . . .	95
3.3.3.	Gráfica diferencia de óxido frente a acero inoxidable . . . . .	98
3.3.4.	Filtro óptimo en paso de energía diferencial frente a total . . .	99
3.4.	Sistemas de detección de microdefectos superficiales de cascarilla residual en tiempo-real . . . . .	100
3.4.1.	Detección con cámara CCD . . . . .	101
3.4.1.1.	Resolución de la cámara . . . . .	103
3.4.1.2.	Aspectos ópticos . . . . .	105
3.4.1.3.	Tiempo de exposición . . . . .	108
3.4.1.4.	Sistema de iluminación . . . . .	125
3.4.1.5.	Capacidad de discriminación y detección de cascarilla mediante diferentes filtros ópticos . . . . .	131
3.4.2.	Detección con sensor fotoeléctrico . . . . .	138
3.4.2.1.	Descripción del sistema de detección mediante sensor fotoeléctrico . . . . .	139
3.4.2.2.	Comparación de esta técnica frente al proceso de imagen . . . . .	140
3.4.2.3.	Resultados obtenidos con sensor láser en laboratorio . . . . .	141
3.4.2.4.	Sistema industrial SICA I para inspección de cascarilla basado en sensores fotoeléctricos . . . . .	143
3.4.2.5.	Adquisición, visualización y reconfiguración dinámica de umbral en tiempo real . . . . .	148
3.4.2.6.	Conclusiones de las pruebas de detección con sensor fotoeléctrico . . . . .	155
3.4.3.	Detección mediante espectroscopia óptica de emisión espacio-temporal . . . . .	157
3.4.3.1.	Método de detección de cascarilla residual en acero inoxidable mediante espectroscopia óptica de emisión resuelta en tiempo y espacio . . . . .	157
3.5.	Conclusiones de los sistemas de detección de cascarilla . . . . .	160

## II Arquitectura ARDIS y entorno-aplicación SIVA II pa-

**ra Inspección de Superficies 165**

<b>4. Diseño de un sistema óptico para inspección visual de superficies basado en iluminación láser</b>	<b>167</b>
4.1. Iluminación basada en diodo láser. Introducción . . . . .	168
4.1.1. Tipos de reflexión. Grano gordo y grano fino del acero inoxidable	170
4.1.2. Características de los láseres utilizados . . . . .	172
4.1.3. Ruido de “speckle” . . . . .	174
4.1.3.1. Utilización del ruido “speckle”. Medición óptica de la rugosidad . . . . .	177
4.2. Lentes . . . . .	178
4.2.1. Lente plano-convexa . . . . .	179
4.2.2. Óptica para adquisición de imagen . . . . .	180
4.2.3. Apertura de haz. Iluminación telecentrica . . . . .	185
4.3. Cámara Sony DXC-950P . . . . .	186
4.4. Formación de imagen . . . . .	188
4.4.1. Iluminación láser coaxial . . . . .	190
4.4.1.1. Sistema físico . . . . .	191
4.4.1.2. Experimentos preliminares . . . . .	192
4.4.1.3. Detección de cascarilla residual . . . . .	199
4.4.2. Iluminación láser exterior . . . . .	204
4.4.2.1. Sistema físico . . . . .	206
4.4.2.2. Detección de cascarilla residual con láser rojo . . . . .	207
4.5. Conclusiones del capítulo . . . . .	209
<b>5. Arquitectura Cognitiva ARDIS</b>	<b>213</b>
5.1. Problemática de inspección de superficies . . . . .	214
5.2. Solución al problema . . . . .	216
5.2.1. Modelado siguiendo la metodología CommonKADS . . . . .	217
5.3. Ontología de la tarea de inspección de superficies . . . . .	218
5.4. Conocimiento genérico del dominio de inspección de superficies . . . . .	220
5.5. Tarea dinámica de inspección de superficies como tarea de diseño-configuración . . . . .	224

5.5.1.	Tarea de Diseño-Configuración de Inspección de Superficies . . .	225
5.5.2.	Subtarea Configurar Esqueleto Inicial . . . . .	231
5.5.3.	Subtarea Proponer extensión esqueleto inicial . . . . .	234
5.5.4.	Subtarea Proponer Extensión Esqueleto Técnicas Visión Artificial . . . . .	243
5.5.4.1.	Subtarea Clasificar/seleccionar Técnica Segmentación	252
5.5.5.	Mecanismo de razonamiento . . . . .	255
5.5.5.1.	Método de razonamiento borroso . . . . .	257
5.6.	Resumen del capítulo . . . . .	265
<b>6.</b>	<b>Entorno-aplicación para inspección de superficies SIVA II</b>	<b>271</b>
6.1.	Introducción . . . . .	271
6.2.	Implementación de la aplicación . . . . .	274
6.3.	Funcionamiento en línea de inspección . . . . .	276
6.4.	Configuración automática del sistema . . . . .	278
6.5.	Configuración semiautomática del sistema . . . . .	282
6.6.	Introducir conocimiento al sistema . . . . .	282
<b>7.</b>	<b>Conclusiones y trabajo futuro</b>	<b>287</b>
<b>A.</b>	<b>Comparación entre Perceptron Multicapa y Mapas Autoorganizados en inspección de cascarilla</b>	<b>297</b>
A.1.	Enfoque Automático . . . . .	298
A.1.1.	Introducción . . . . .	298
A.1.2.	Sistema de inspección y software utilizado . . . . .	300
A.1.2.1.	Cámara . . . . .	300
A.1.2.2.	Frame Graber . . . . .	300
A.1.2.3.	Librerías MIL . . . . .	301
A.1.2.4.	Matlab . . . . .	301
A.1.3.	Ajuste automático de foco . . . . .	302
A.1.3.1.	Red neuronal para autoajuste de foco . . . . .	302
A.1.3.1.1.	Tipo de red . . . . .	302
A.1.3.1.2.	Vector de características . . . . .	305

A.1.3.1.3.	Capas de la red, entradas y salidas . . . . .	312
A.1.3.1.4.	Conjunto de entrenamiento y prueba . . . . .	314
A.1.3.2.	Entrenamiento de la red . . . . .	315
A.1.3.2.1.	Entrenamiento con tres clases de salida . . . . .	315
A.1.3.2.2.	Entrenamiento con dos clases de salida . . . . .	317
A.1.3.3.	Prueba de la red . . . . .	317
A.1.3.4.	Programa en C++ para adquisición de imagen . . . . .	319
A.1.3.5.	Funcionamiento continuo de autofocus en tiempo-real . . . . .	320
A.1.4.	Detección de cascarilla en la imagen autoenfocada . . . . .	324
A.2.	Segmentación y clasificación de cascarilla residual mediante redes SOFM	331
A.2.1.	Problema a solucionar y método para solucionarlo . . . . .	332
A.2.2.	Descripción del problema y recursos para la solución del problema (imágenes y vectores de características) . . . . .	334
A.2.3.	Formas de evaluar la calidad de la solución . . . . .	336
A.2.4.	Subtareas del problema. Solución mediante SOFM . . . . .	339
A.2.4.1.	Método 1. Vectores de características . . . . .	341
A.2.4.2.	Método 2. Imagen directa . . . . .	348
<b>B.</b>	<b>Diagramas de actividad de la arquitectura ARDIS</b>	<b>355</b>
<b>C.</b>	<b>Diagramas de clases de la arquitectura ARDIS</b>	<b>357</b>
<b>D.</b>	<b>Estructura de control en la arquitectura ARDIS</b>	<b>359</b>



# Índice de figuras

1.1.	Representación del sistema para medida de planitud [Garcia et al., 1999] . . . . .	44
1.2.	Sistema de inspección de planitud en el laboratorio [Garcia et al., 1999]	45
1.3.	Sistema de inspección de planitud, integrado en el entorno real de fabricación de acero [Garcia et al., 1999] . . . . .	45
1.4.	Etapas en una arquitectura de visión para percepción . . . . .	52
1.5.	Principales grados de libertad de los sistemas de visión industrial . .	57
2.1.	Arquitectura de visión para percepción dinámica (Arquitectura: ARDIS; Entorno-Aplicación: SIVAI) . . . . .	68
2.2.	Arquitectura de visión para percepción y comportamiento dinámico (Arquitectura: ARDIS; Entorno-Aplicación: SIVAI) . . . . .	69
2.3.	Tres áreas computacionales de la arquitectura para entendimiento de escenas dinámicas [Chella et al., 2000] y las relaciones entre ellas . . .	72
2.4.	Arquitectura de un sistema de visión artificial autoajutable. El sistema posee varias etapas de procesado, en las cuales se pueden elegir diferentes algoritmos. Cada algoritmo puede tener uno o más parámetros ajustables. El usuario evalúa los resultados de procesado y el módulo de control usa esta realimentación para cambiar algoritmos o parámetros con el objetivo de mejorar los resultados [Shekhar et al., 1999]	75
2.5.	(a) Estrategia clásica, (b) Estrategia planteada en esta tesis; para abordar el problema de inspección superficial en la industria . . . . .	80
3.1.	(a) Plancha de acero tipo B. Acabado superficial brillante. Grano gordo, (b) Plancha de acero tipo D. Acabado superficial mate. Grano fino . . . . .	93
3.2.	Reflectancia frente a longitud de onda. (a)-(f), 6 muestras de acero comparadas con 6 de óxido . . . . .	96

3.3. (a) Reflexión en la primera muestra de acero, donde se señala la región del espectro electromagnético correspondiente al visible y al IR cercano. (b) Detalle del visible, donde se observa poca dispersión en comparación con el IR cercano . . . . .	97
3.4. Reflectancia media de las 6 muestras . . . . .	98
3.5. Desviación estándar de las 6 gráficas de acero y óxido . . . . .	99
3.6. Diferencia de reflectancia entre acero y óxido para cada longitud de onda. Se observa claramente un máximo relativo, aproximadamente, en 550 nm . . . . .	100
3.7. Cubrimiento logrado con una cámara de 1024 x 1024 píxeles y a una velocidad de captura de 40 fotogramas/seg . . . . .	104
3.8. Esquema de muestreo en zig-zag con cámara de 1024 x 1024 y 40 fotogramas/seg. PPM = 20 píxeles/mm . . . . .	105
3.9. Óptica. Modelo de lente fina . . . . .	106
3.10. Notación usada en el estudio teórico del tiempo de exposición . . . . .	109
3.11. Intervalos temporales en el estudio teórico del tiempo de exposición (a) Mancha no ha llegado al píxel, (b) Mancha antes de ser vista completamente, (c) Mancha vista completamente, (d) Mancha después de ser vista completamente, (e) Mancha ha pasado del píxel . . . . .	114
3.12. Representación del valor del píxel en función del tiempo de exposición (Caso particular: $\Delta = l_m$ y $l_m = 2l_p$ ) . . . . .	118
3.13. Contribución de la mancha al valor del píxel para distintos tamaños de $l_m$ (Condiciones iniciales: $\Delta = l_m$ ó $t_1 = 0$ ) . . . . .	119
3.14. Situación inicial de la mancha en la extensión del modelo a varios píxeles . . . . .	120
3.15. Valores de los píxeles $P_1, P_2, \dots, P_n$ en función del tiempo de exposición	121
3.16. Valores normalizados de los píxeles $P_1, P_2, \dots, P_n$ en función del tiempo de exposición . . . . .	122
3.17. Imagen de referencia para la representación de los valores obtenidos de las ecuaciones como una imagen . . . . .	123
3.18. Simulación de imágenes. (a) $T_{exp} = t_{pix}$ , (b) $T_{exp} = t_{man}$ , (c) $T_{exp} = t_{man} + t_{pix}$ y (d) $T_{exp} = 2t_{man}$ . La columna de la izquierda es a plancha parada y la de la derecha con la plancha en movimiento . . . . .	124
3.19. (a) Imagen de una plancha de acero inoxidable brillante y grano grueso, con iluminación oblicua, (b) Ídem, pero, en este caso mate y grano fino . . . . .	127

3.20. (a) Sistema de iluminación basado en tubos fluorescentes cilíndricos, (b) Anillo de luz de “Stoker & Yale”, (c) Difusor SCDI de “Nerlite” . . . . .	128
3.21. (a) Imagen capturada con una única fuente de iluminación, (b) Con dos fuentes, (c) Imagen capturada con tiempo de exposición elevado para aumentar el rango dinámico de la imagen . . . . .	130
3.22. (a) Plancha tipo B; características de la imagen: tomada con cámara digital, RGB, sin filtro, resolución: $2048 \times 1536$ , $T_{exp}$ : 0.0333 seg., $F/\#$ : 2.5, distancia focal: 21, sin flash y luz natural. (b) Plancha ti- po C; características de la imagen: tomada con cámara digital, RGB, sin filtro, resolución $2048 \times 1536$ , $T_{exp}$ : 0.025 seg., $F/\#$ : 2.5, distancia focal: 21, sin flash y luz natural . . . . .	132
3.23. Plancha tipo B; características de la imagen: adquirida con lupa elec- trónica, RGB, sin filtro, resolución: $320 \times 240$ e iluminación artificial . . . . .	132
3.24. (a) Cámara digital, RGB, filtro verde, sin flash y luz natural; (b) Lu- pa electrónica, RGB, filtro verde e iluminación artificial; (c) Cámara digital, RGB, filtro rojo, sin flash y luz natural; (d) Cámara digital, RGB, filtro amarillo, sin flash y luz natural; (e) Cámara digital, RGB, filtro polarizador, sin flash y luz natural; (f) Lupa electrónica, RGB, filtro polarizador e iluminación artificial . . . . .	134
3.25. Plancha tipo C y cámara digital: (a) plano de color verde, (b) histo- grama del plano de color verde, (c) primera imagen binaria (localiza los píxeles de cascarilla residual (semillas)), (d) segunda imagen bi- naria con umbral mayor para detectar completamente las manchas, sombras e imperfecciones, (e) manchas de cascarilla residual y (f) his- tograma de la imagen binaria (e) para medir la cantidad de cascarilla . . . . .	136
3.26. Plancha tipo C; Resumen de los tres planos de color, imagen tomada con lupa electrónica y filtro verde . . . . .	137
3.27. Plancha tipo C. Resumen de los tres planos de color; imagen tomada con cámara digital y filtro polarizador . . . . .	137
3.28. Plancha tipo C. Resumen de los tres planos de color; imagen tomada con lupa electrónica y filtro polarizador . . . . .	138
3.29. El cabezal láser se montó en un centro de mecanizado, el cual barrió a una velocidad de 1 m/min dos planchas diferentes. . . . .	142
3.30. Umbral establecido en el amplificador: 850 (valores por encima de 850 dan una salida de 12 voltios => acero y valores por debajo de 850 dan una salida de 0 voltios => óxido) después de haber realizado el ajuste (así, se afina en la detección de cascarilla residual) . . . . .	142
3.31. Entorno de inspección de cascarilla residual en laminados de acero inoxidable . . . . .	144

3.32. Sistema para inspección superficial de acero inoxidable SICA I . . . .	145
3.33. Esquema general del sistema para inspección superficial de acero in- oxidable SICA I . . . . .	146
3.34. (a) Cabezal láser, (b) Amplificador . . . . .	147
3.35. Diagrama de bloques de la adquisición, por puerto paralelo, de los datos binarios de inspección del sensor fotoeléctrico . . . . .	149
3.36. Esquema de realimentación para control de umbral . . . . .	151
3.37. Histograma realizado con 7000 datos de reflectancia . . . . .	152
3.39. Imagen de acero inoxidable con defecto de cascarilla residual . . . . .	152
3.38. Interfaz de usuario que muestra el histograma cada minuto y la va- riación de umbral cada 3 minutos de inspección . . . . .	153
3.40. (a) Tarjeta de adquisición por puerto paralelo, (b) Una de las tarjetas de control automático de umbral . . . . .	154
3.41. Esquema general de un diseño industrial futuro para inspección con varios sensores fotoeléctricos . . . . .	156
3.42. Comparación de los espectros de emisión de la muestra de acero in- oxidable con cascarilla residual (tipo D) y de hierro oxidado . . . . .	158
3.43. Espectros de emisión de la muestra de acero inoxidable con cascarilla residual (tipo D) obtenidos bajo irradiación con 1, 10 y 100 pulsos láser	159
4.1. (a) Reflexión especular, (b) Reflexión difusa . . . . .	171
4.2. (a) Plancha de acero tipo B. Acabado superficial brillante y grano gordo. Imagen capturada con lupa electrónica, (b) Plancha de acero tipo D. Acabado superficial mate y grano fino. Imagen capturada con lupa electrónica . . . . .	171
4.3. (a) Diodo láser rojo de la marca “Melles Griot”, (b) Diodo láser verde de la marca “Vector” . . . . .	174
4.4. (a) Ruido de speckle en una plancha de acero inoxidable tipo B, (b) Ruido de speckle en una plancha de acero inoxidable tipo C . . . . .	176
4.5. (a) Lentes plano convexas de Melles Griot, (b) Diagrama de trazado de rayos en una lente plano-convexa (Simbología de Melles Griot) . .	181
4.6. Óptica. Modelo de lente fina . . . . .	182
4.7. Iluminación telecentrica . . . . .	185
4.8. (a-b) Imágenes capturadas con cámara SONY, y óptica e iluminación convencional, (c-f) Imágenes capturadas con cámara SONY, óptica convencional e iluminación láser . . . . .	189

4.9. Sistema de iluminación láser coaxial . . . . .	191
4.11. Sistema para iluminación láser de la superficie a inspeccionar sin utilizar difusor giratorio . . . . .	192
4.10. Banco óptico recién salido del taller mecánico y primeras pruebas de funcionamiento . . . . .	193
4.12. (a) Sistema de enfoque con $M=1$ y lente plano-convexa ( $f=160\text{mm}$ ), (b) Esquema de haces incidente y reflejado, (c) Iluminación con difusor estático . . . . .	194
4.13. (a) Lente plano-convexa de enfoque (la estructura que la sujeta actúa también de diafragma), (b) Detalle de la superficie iluminada, (c) Haz láser que atraviesa el cubo semireflectante y la lente de enfoque, (d) Iluminación de la plancha de acero con difusor estático, (e) Iluminación con difusor girando, (f) Superficie iluminada con el difusor girando . . . . .	195
4.14. (a) Imagen tomada con iluminación coaxial. Se observa ruido “speckle”, (b) Eliminación completa de ruido “speckle” en la imagen, (c) Interferencia debida a luz láser procedente del cubo semireflectante, (d-f) Ruido de speckle en el sistema de iluminación láser coaxial . . .	198
4.15. (a) Patrón de interferencia debido a iluminación láser, sin difusor y lente de $f=160\text{mm}$ , (b) Patrón de interferencia, sin plancha de acero a inspeccionar, (c) Patrón de interferencia generado por el cubo semireflectante, (d) “Speckle” en el sistema óptico coaxial completo, (e) Eliminación de ruido “speckle” debido al giro del difusor . . . . .	200
4.16. (a) Configuración para inspección coaxial con lente de enfoque de distancia focal 55 mm, (b) Detalle del haz láser en las distintas partes del sistema de inspección coaxial, para detección de defectos de cascarilla en acero inoxidable. . . . .	202
4.17. Detección de cascarilla residual con el sistema de inspección láser coaxial	204
4.18. Conjunto de imágenes con defectos de cascarilla residual y parte de un número 3 grabado en la superficie de la plancha de acero inoxidable	205
4.19. (a) Sistema de iluminación láser exterior, (b) Detalle del modulo de iluminación láser, (c) Plancha de acero inoxidable iluminada con luz láser, (d) Detalle de apertura del haz láser, (e) Detalle de aislamiento del CCD, (f) Detalle de la lente de enfoque ( $f=55\text{mm}$ ) y cámara Sony DXC-950P . . . . .	208
4.20. (a) Inspección de acero inoxidable mediante iluminación láser exterior y lente de $f=160\text{ mm}$ , (b) Aparición de “speckle” al quitar el difusor del sistema de iluminación . . . . .	210

4.21. (a-b) Detección de defectos superficiales de cascarilla residual en una plancha de acero inoxidable, mediante iluminación láser exterior . . .	211
5.1. Relaciones entre tipos de conocimiento del dominio de inspección de superficies . . . . .	222
5.2. Descomposición jerárquica de la tarea de Diseño-Configuración de Inspección de Superficies . . . . .	225
5.3. Diagrama de subtareas e inferencias del PSM Proponer-y-Revisar(1) para la tarea de Diseño-Configuración de Inspección de Superficies . . . . .	228
5.4. Descomposición jerárquica de la subtaska Configurar esqueleto inicial	231
5.5. Diagrama de subtareas e inferencias del PSM Proponer-y-Revisar(2) para la subtaska Configurar esqueleto inicial . . . . .	232
5.6. Descomposición jerárquica de la subtaska Proponer Sistema . . . . .	236
5.7. Diagrama de subtareas e inferencias del PSM Descomponer-Configuración-En-Partes para la subtaska Proponer Sistema . . . . .	237
5.8. Descomposición jerárquica de la subtaska Proponer Extensión Esqueleto Técnicas Visión Artificial . . . . .	246
5.9. Diagrama de subtareas e inferencias del PSM Descomponer-Técnicas-Visión-en-Partes para la subtaska Proponer Extensión Esqueleto Técnicas Visión Artificial . . . . .	247
5.10. Diagrama de subtareas e inferencias del PSM Cubrir-y-Diferenciar para la subtaska Clasificar/seleccionar Técnica Segmentación . . . . .	253
5.11. Entradas [Frecuencia Procesador (GHz)], [Memoria RAM (Mb)] y [Transferencia de Imágenes (fps)] en el razonamiento borroso para obtener la salida [Velocidad Sistema Inspección] (numérica y lingüística)	260
5.12. Proceso de razonamiento borroso en la arquitectura ARDIS para obtener la salida [Velocidad Sistema Inspección] (numérica y lingüística)	262
5.13. Entradas [Velocidad Sistema Inspección] y [Tiempo de Exposición (ms)] en el razonamiento borroso para obtener la salida [Tiempo Procesado por Imagen (seg)] (numérica y lingüística) . . . . .	263
5.14. Proceso de razonamiento borroso en la arquitectura ARDIS para obtener la salida [Tiempo Procesado por Imagen (seg)] (numérica y lingüística) . . . . .	264
5.15. Diagrama global de la arquitectura ARDIS . . . . .	266

6.1. Pantalla principal de la aplicación desarrollada para configurar el sistema SIVA II, y adquirir y validar el conocimiento del experto a través del inspector de línea . . . . .	275
6.2. Pantalla del modo “Funcionamiento en línea de inspección” de la aplicación . . . . .	279
6.3. Pantalla del modo “Configuración automática del sistema” de la aplicación . . . . .	283
6.4. Pantalla del modo “Configuración semiautomática del sistema” de la aplicación . . . . .	284
6.5. Pantalla del modo “Introducir conocimiento al sistema” de la aplicación	286
A.1. Red neuronal MLP propuesta para clasificar la imagen de entrada en enfocada o desenfocada . . . . .	304
A.2. Pequeña imagen en escala de grises y su matriz de co-ocurrencia . . .	307
A.3. Vector de 36 características de entrada a la red neuronal MLP, que es capaz de diferenciar entre una imagen enfocada y otra desenfocada	309
A.4. (a) Imagen RGB enfocada, (b) Imagen RGB desenfocada . . . . .	310
A.5. (a) Transformada de Fourier del plano de color Rojo de la imagen RGB 4.4 (a), (b) Transformada de Fourier del plano de color Rojo de la imagen RGB 4.4 (b) . . . . .	311
A.6. Capa de entrada de la red neuronal MLP . . . . .	312
A.7. Capa oculta de la red neuronal MLP . . . . .	313
A.8. Capa de salida de la red neuronal MLP . . . . .	314
A.9. Error cuadrático medio después de 10000 ciclos de entrenamiento . .	316
A.10.(a) Error cuadrático medio después de 2707 ciclos de entrenamiento (objetivo de error 0.001), (b) Error cuadrático medio después de 10000 ciclos de entrenamiento (objetivo de error $1e^{-5}$ ) . . . . .	318
A.11.Diagrama de flujo del programa de adquisición de imágenes . . . . .	320
A.12.Algoritmo de autoenfoque con red neuronal MLP . . . . .	322
A.13.Imagen enfocada automáticamente en el experimento 1 . . . . .	323
A.14.Imagen enfocada automáticamente en el experimento 2 . . . . .	324
A.15.(a) Detalle del plano de color rojo, (b) Localización del detalle de la figura (a) en el plano rojo. En (a) y (b), se visualiza solo el rango de niveles de gris [80 130] . . . . .	326
A.16.Plano de color rojo después de aplicar el filtro pasa alta . . . . .	327
A.17.Umbralización de valor 81, en el plano de color rojo filtrado pasa alta	327

A.18.(a) Detalle de cascarilla en la imagen filtrada pasa alta, (b) Localización del detalle de cascarilla de la figura (a) en la imagen filtrada, (c) Detalle de ruido en la imagen filtrada pasa alta, (d) Localización del detalle de ruido de la figura (c) en la imagen filtrada. En las cuatro figuras solo se sombrea el rango de niveles de gris [50 100] . . . . .	329
A.19.(a) Entropía local del plano de color rojo, (b) Entropía local del plano de color rojo filtrado pasa alta, (c) Matriz de co-ocurrencia del plano de color rojo, (d) Matriz de co-ocurrencia del plano de color rojo filtrado pasa alta . . . . .	330
A.20.Imagen original con defectos de cascarilla residual . . . . .	335
A.21.(a) Característica 0; Plano de color original, (b) Característica 1; Ecualización del histograma, (c) Característica 2; Ajuste de intensidad, (d) Característica 3; Filtro de valor medio usando vecindad $3 \times 3$ , (e) Característica 4; Filtro valor mínimo usando vecindad $3 \times 3$ , (f) Característica 5; Filtro valor mediano usando vecindad $3 \times 3$ . . . . .	337
A.22.(a) C6; Filtro valor máximo usando vecindad $3 \times 3$ , (b) C7; Filtro utilizando el método de Wiener y usando vecindad $3 \times 3$ , (c) C8; Operación morfológica de cierre usando vecindad $3 \times 3$ , (d) C9; Operación morfológica de apertura usando vecindad $3 \times 3$ , (e) C10; Operación morfológica de dilatación usando vecindad $3 \times 3$ , (f) C11; Operación morfológica de erosión usando vecindad $3 \times 3$ . . . . .	338
A.23.SOFM entrenada con Característica 1 y Característica 2 . . . . .	343
A.24.(a) SOFM "Box Distance" entrenada con Característica 1 y Característica 4, (b) SOFM "Box Distance" entrenada con Característica 1 y Característica 12 . . . . .	345
A.25.SOFM Ventana defecto cascarilla; Plano Verde; entrenada con Característica 1 y Característica 5 . . . . .	346
A.26.Reducción de dimensión $12 \Rightarrow 3$ . Solo se muestran dos dimensiones del vector de características en la segunda grafica debido a que no se pueden visualizar todas las dimensiones. El rango de entrada ha sido [0 255] y los vectores solo se han pasado 1 vez . . . . .	348
A.27.(a) Red SOFM entrenada con vector de características formado por dos píxeles (capa de entrada) de la imagen (plano de color verde) y 4 neuronas en la capa de salida, (b) Igual que el caso (a) excepto que la capa de salida posee 64 neuronas . . . . .	350
A.28.Red SOFM entrenada con vector de características formado por dos píxeles (capa de entrada) de una pequeña imagen $16 \times 16$ (con defecto de cascarilla) y 4 neuronas en la capa de salida, (b) Igual que el caso (a) excepto que la capa de salida posee 16 neuronas . . . . .	351

---

A.29.(a) Imagen tras realizar un ajuste de intensidad en el plano de color verde, (b) Imagen recortada de la anterior que contiene un pequeño defecto de cascarilla . . . . .	352
A.30.(a) Vector con dos características (2 píxeles), 4 neuronas de salida y 1 época de entrenamiento (imagen $128 \times 256$ ), (b) Igual que (a) pero en este segundo caso se utiliza un pequeño recorte ( $16 \times 16$ ) de la imagen utilizada en (a) . . . . .	353



# Índice de tablas

1.1. Análisis de algunas de las revisiones o recopilaciones mas relevantes en el ámbito de las aplicaciones de inspección mediante sistemas de visión industrial por computador . . . . .	56
1.2. Sistemas reales de visión industrial para inspección de calidad superficial y sus grados de libertad correspondientes . . . . .	59
1.3. Tipos y características de defectos superficiales en inspección industrial	60
2.1. Recopilación de algunas arquitecturas dinámicas y reconfigurables para visión artificial en el nivel del conocimiento y de la aplicación . . .	77
3.1. Valores normalizados de los píxeles para varios tiempos de exposición	123
5.1. Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): entorno; y sus valores posibles . . . . .	221
5.2. Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): defecto superficial; y sus valores posibles .	221
5.3. Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea Proponer-Extensión-Esqueleto-Diagnostico-Calidad (ver apéndice B) . . . . .	223
5.4. Requisitos globales para la configuración del sistema de inspección de la superficie específica y sus valores posibles . . . . .	229
5.5. Requisitos iniciales para la configuración del sistema de inspección de la superficie específica y sus valores posibles . . . . .	233
5.6. Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea Configurar-esqueleto-inicial (figura 5.5) . . . . .	235
5.7. Requisitos de entorno para la configuración del sistema de inspección de la superficie específica y sus valores posibles . . . . .	239

5.8. Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea Proponer-Extensión-Esqueleto-Entorno (figura 5.7) . . . . .	240
5.9. Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea Proponer-Extensión-Esqueleto-Entorno (continuación tabla 5.7) . . . . .	241
5.10. Requisitos de tiempo-real para la configuración del sistema de inspección de la superficie específica y sus valores posibles . . . . .	243
5.11. Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea Proponer-Extensión-Esqueleto-Tiempo-Real (figura 5.7) . . . . .	244
5.12. Requisitos de las técnicas de visión por computador para la configuración del sistema de inspección de la superficie específica y sus valores posibles . . . . .	247
5.13. Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): técnicas de visión por computador . . . .	250
5.14. Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial (figura 5.9) . . . . .	251
5.15. Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): propiedades de las técnicas para segmentar defectos superficiales; y sus valores posibles . . . . .	254
A.1. Recopilación de varios artículos donde el tipo de red utilizado es un perceptron multicapa (MLP) . . . . .	303
A.2. Recopilación de varios artículos sobre redes SOFM en visión artificial	340
D.1. Estructura de control: secuencia de ejecución de las subtareas e inferencias de la tarea Diseño-Configuración de Inspección de Superficies (continua en la siguiente tabla D.2) . . . . .	360
D.2. Continuación de la tabla D.1 . . . . .	361
D.3. Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Configurar Esqueleto Inicial (continua en la siguiente tabla D.4) . . . . .	362
D.4. Continuación de la tabla D.3 . . . . .	363
D.5. Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Proponer extensión esqueleto inicial (continua en la siguiente tabla D.6) . . . . .	364

D.6. Continuación de la tabla D.5 . . . . .	365
D.7. Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Proponer extensión esqueleto entorno (continua en la siguiente tabla D.8) . . . . .	366
D.8. Continuación de la tabla D.7 . . . . .	367
D.9. Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Proponer extensión esqueleto tiempo-real (continua en la siguiente tabla D.10) . . . . .	368
D.10.Continuación de la tabla D.9 . . . . .	369
D.11.Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Proponer extensión esqueleto diagnostico calidad	370
D.12.Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Proponer extensión esqueleto técnicas visión artificial (continua en la siguiente tabla D.13) . . . . .	371
D.13.Continuación de la tabla D.12 . . . . .	372
D.14.Continuación de la tabla D.13 . . . . .	373
D.15.Estructura de control: secuencia de ejecución de las inferencias de la subtarea Clasificar/seleccionar Técnica Segmentación . . . . .	374
D.16.Estructura de control: secuencia de ejecución de las inferencias de la subtarea Clasificar/seleccionar Representador . . . . .	375



# Parte I

## Estado del Arte y Métodos Experimentales para la Inspección de Superficies



# Capítulo 1

## Sistemas de inspección visual industrial

Los sistemas de inspección visual en la industria son un campo de investigación activa debido a la variedad de aplicaciones que se pueden desarrollar y a las necesidades actuales del sector industrial. En este primer capítulo se refleja esta actividad desde el punto de vista de los sistemas de visión por computador en la industria y de sus aplicaciones. Esto nos lleva a aclarar en este capítulo desde la definición general de visión por computador hasta los sistemas de inspección de superficies más específicos en la industria actual.

Los sistemas de visión por computador en entornos industriales proporcionan soluciones en el campo industrial. Una plétora de actividades industriales se han beneficiado de la utilización de sistemas de visión artificial en procesos de fabricación [Malamas et al., 2003]. Estas actividades son de diversa naturaleza, por ejemplo: fabricación de componentes electrónicos delicados y circuitos integrados [Sanz & Petkovic, 1988] [Li & Lin, 1994], producción textil de buena calidad [Bahlmann et al., 1999], productos impresos [Torres et al., 1998], inspección de la calidad del granito [Shafarenko et al., 1997], inspección de gotas de vidrio [Laizola et al., 2003], etc.

Los sistemas de visión por computador mejoran la productividad y el control de calidad, y proporciona ventajas a las industrias que utilizan esta tecnología [Malamas et al., 2003]. Los sistemas de visión junto con algoritmos eficientes permiten mejorar la productividad, el acabado final del producto, la calidad, la precisión y minimizan la carga de trabajo rutinaria del operario (maximizando su carga de control y supervisión). Estos factores hacen que, hoy en día, se estén incorporando numerosos sistemas de visión por computador para la solución de problemas de calidad dimensional, calidad superficial, ensamblaje de piezas y observación del correcto funcionamiento de maquinas.

## **1.1. Visión por computador (“Computer Vision”)**

La visión artificial o visión por computador o visión computacional tiene como finalidad la reproducción artificial del sentido de la vista. Es decir, visión basada en computador, puesto que es impensable otorgar a una máquina cierto grado del sentido de la vista sin que se utilice un computador, tanto para la etapa temprana (puramente sensorial) como para la fase avanzada que demanda mayor complejidad de procesamiento [Maravall Gómez-Allende, 1993].

Los primeros trabajos con imágenes se realizaron en los años 70 [Tenenbaum, 1970], [Rosenfeld et al., 1976]; pero realmente se empezó a trabajar en el campo en los años 80 [Leclerc & Zucker, 1987], [Nalwa & Binford, 1986], [Haralick & Shapiro, 1985], con la aparición de las primeras computadoras capaces de procesar gran cantidad de datos.

El tratamiento digital de imágenes y la visión computacional han experimentado una rápida evolución en las últimas dos décadas. Entre las razones de este avance se puede destacar el incremento de prestaciones del hardware de propósito general (utilizado para realizar los numerosos cálculos necesarios en un tiempo razonable o tiempo-real de la aplicación específica), el carácter interdisciplinar de estas materias

(en relación con áreas como la inteligencia artificial, la robótica, los gráficos por computador o las matemáticas) y, fundamentalmente, al crecimiento del número y tipo de aplicaciones industriales que demandan el uso de técnicas de visión por computador [Vélez et al., 2003].

En el estado actual, en vez de existir un abundante conjunto de métodos para solucionar diversas tareas, bien definidas, de visión por computador; nos encontramos con métodos para una tarea específica y difícilmente reutilizables para otras aplicaciones [Zhang et al., 2003], [Su et al., 2003]. Los métodos, las aplicaciones, los algoritmos, etc. están en fase de investigación básica [Adameck et al., 2003], [Venkatachalam et al., 2003], [Bourgeat et al., 2003] aunque en los últimos años se han empezado a integrar en productos comerciales [ProVision, 2003], [NeuroCheck, 2006]; inicialmente solucionaban tareas sencillas y poco a poco van abordando tareas complejas, como por ejemplo: sistemas basados en imágenes médicas [Rincón, 2002], detección de objetos en movimiento [Mira et al., 2004], [López et al., 2006], control de calidad en procesos de producción industriales [Smith & Smith, 2003], [Zhou, 1999], agricultura de precisión [Ribeiro et al., 2003], distribución de flujo de combustible en placas bipolares [Martín et al., 2006], [Martín et al., 2004], etc.

La imagen es la principal fuente de información de la visión por computador que junto con el conocimiento del dominio permite, por ejemplo, controlar el comportamiento de un sistema, realizar una tarea de inspección, etc.

## 1.2. Visión industrial por computador (“Machine Vision”)

La visión industrial por computador es la aplicación de la visión por computador en la industria [Zuech, 2000], [Langenbach et al., 2001], [Kohler et al., 2001]. Por lo tanto, no sólo requiere de técnicas de procesamiento de imagen, sino también

de dispositivos digitales de entrada/salida, redes de ordenadores para controlar equipos del proceso de fabricación, etc. Además, la interrelación entre las técnicas de visión artificial y los dispositivos de medición-actuación ha de ser tratada con especial atención, en las fases incipientes de un sistema de visión industrial. Esto conduce a englobar métodos de diferentes disciplinas, por ejemplo: inteligencia artificial [Sun & Fisher, 2003], óptica [Stokman & Gevers, 2000], electrónica [Preciado et al., 2001a], [Montúfar-Chaveznava et al., 2001b], iluminación [Seulin et al., 2001], etc.

Una de las aplicaciones más comunes de la visión industrial por computador es la inspección de productos en la propia línea de fabricación [Guinea et al., 2000], [García et al., 2001], de esta forma se establece un control de calidad más eficiente. En una línea de producción se pueden inspeccionar, entre otros, semiconductores [Gallegos-Hernandez et al., 2002], tejidos [Allgood et al., 2000], productos alimenticios [García-Alegre et al., 2000], [Fernandez et al., 2002], materiales laminados [Pham & Alcock, 1997], [Kang & Liu, 2005], automóviles [Chung & Kim, 1998] etc.

En la mayoría de los casos en la línea de inspección, el inspector examina visualmente un producto para diagnosticar la calidad. Por tanto, el objetivo de los sistemas de visión industrial es ayudar al inspector a realizar las tareas de inspección de calidad [Altamirano et al., 2000]; mediante cámaras digitales especiales [Okada et al., 2002], [Waeny & Schwider, 2002], sensores inteligentes [Poujouly & Journet, 2002], electrónica para funcionamiento en tiempo-real de la aplicación [Montúfar-Chaveznava et al., 2001a], [Preciado et al., 2001b], [Arias-Estrada & Torres-Huitzil, 2000], software para procesado de imagen [OpenCV, 2001], ordenadores industriales [AdvantechIndustrialComputer, 2007], modelos de las aplicaciones, diagnósticos precisos de la calidad de un producto [Geveaux et al., 2000], etc. De esta forma, se consigue emular el comportamiento del experto humano en la realización de las tareas de inspección.

Los sistemas de visión industrial se programan para realizar tareas muy definidas

y acotadas (sistemas ad-hoc), como es el caso de: contar objetos en una cinta transportadora, leer números de serie o códigos de barras en un producto, inspección de defectos superficiales, medir piezas, detectar partes no ensambladas en un producto, etc [Guda et al., 2000].

Por otro lado, los fabricantes prefieren sistemas de visión industrial, para las inspecciones visuales que requieren alta velocidad, alto aumento óptico, funcionamiento 24 horas/día, repetibilidad y precisión de las medidas, etc. Frecuentemente, estas tareas las realizan operarios cualificados/inspectores en las líneas de producción, pero a pesar de que la percepción de los objetos es instantánea, poseen una gran flexibilidad para adaptarse a cualquier tipo de problema nuevo o políticas de calidad variables, tienen una capacidad inigualable de clasificación, etc.; la eficiencia decae debido a factores como la distracción, forma física o pequeñas dolencias, cansancio, etc.

En resumen, los sistemas de visión industriales por computador son capaces de procesar imágenes, pero son diseñados para realizar una tarea única y repetitiva. Actualmente, los sistemas de visión industriales no pueden igualarse al entendimiento de la imagen, a la tolerancia frente a las variaciones de iluminación, a la respuesta frente a la degradación de la imagen, a la adaptación en función de la variabilidad de las partes de la imagen, a la capacidad de clasificación y reconocimiento de objetos o defectos, etc. del operario especializado/inspector de la línea de producción. Por estas razones, queda abierta una línea de investigación que conduce a modelar los sistemas de visión industrial por computador; con el objetivo de resolver las tareas del inspector de la forma más eficiente y beneficiosa para la industria.

### **1.3. Inspección visual manual**

Tradicionalmente, la inspección visual y el control de calidad se han realizado por expertos de cada tipo de industria. La inspección visual manual de cada proceso

productivo tiene asociado un conocimiento propio, que permite, formar a los operarios para una tarea de inspección concreta. Esta forma de inspeccionar es rutinaria y costosa para el operario. Y poco eficiente para el proceso productivo debido a que es lenta y no permite observar todo el problema.

Las actividades de inspección manual son enteramente llevadas a cabo por inspectores humanos, que adquieren el conocimiento de inspección de cada proceso de producción. En tales situaciones es difícil lograr inspecciones casi libres de error. El rendimiento de la inspección manual depende de factores relacionados con el trabajo, factores del entorno de inspección (accesibilidad del inspector al punto de inspección), factores de organización del trabajo, motivación del inspector y factores personales. Los factores específicos que influyen directamente en la realización de inspecciones manuales son los siguientes: el ritmo impuesto por la tarea, la complejidad de la tarea, el tiempo de inspección, la densidad de defectos, el método de inspección, la iluminación, la estrategia de inspección, la realimentación, el entrenamiento y la edad [Mital et al., 1998]. En general, los costes asociados con la inspección manual incluyen el coste del inspector, el coste de los falsos positivos, el coste de los falsos negativos y costes no estimados como por ejemplo, pérdidas debidas a una mala percepción de la calidad de los productos.

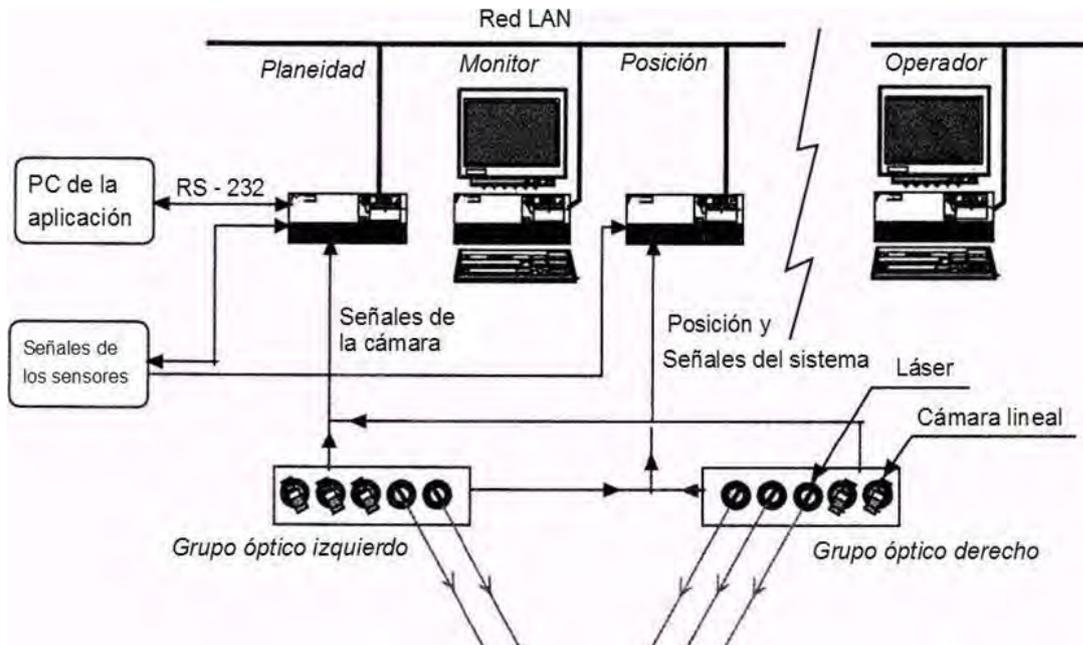
En muchos casos los humanos realizan las inspecciones mejor que los sistemas de inspección visual. Incluso, la mejora de la calidad es posible, a través de, mejoras en el rendimiento humano [Govindaraju et al., 2001]. Pero tienen la desventaja de ser más lentos y que se cansan rápidamente. Además, es difícil encontrar o mantener en determinadas tareas de inspección de superficies a expertos humanos. Estos requieren un entrenamiento específico de la inspección a realizar y el desarrollo de sus habilidades puede llevar bastante tiempo. También, existen casos donde la inspección industrial puede ser difícil o peligrosa incluso para los inspectores mejor entrenados. Por ejemplo, inspección debajo del agua, industria nuclear, industria química, etc. [Kopardekar et al., 1993].

## 1.4. Sistemas de visión industrial

En los años 80, 90 y comienzos del siglo XXI se han desarrollado numerosos sistemas de visión industrial, orientados a una tarea concreta. La situación que se plantea al tratarse de soluciones ad-hoc es la siguiente: 1) se plantea el problema a un grupo de expertos en visión artificial, 2) el grupo de expertos diseña e integra una solución para el problema industrial concreto utilizando las herramientas de visión artificial (software, hardware, iluminación exterior, etc.), y 3) el sistema ad-hoc diseñado por los expertos queda en desuso si el problema inicial cambia.

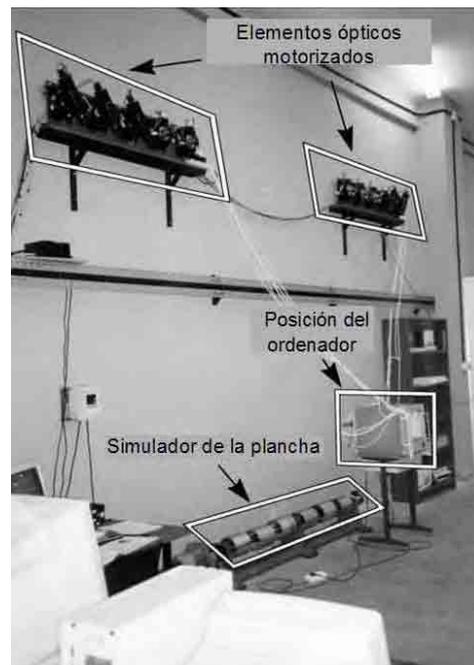
En la figura 1.1 se observa, como ejemplo de sistema ad-hoc, el esquema de un sistema para medida de “cómo o cuánto de plana” es una superficie. Una superficie se considera plana cuando está totalmente comprendida entre dos planos paralelos separados entre sí una cierta tolerancia (de ahora en adelante utilizaremos la palabra “planitud” para designar “cómo o cuánto de plana” es una superficie). El sistema de inspección de planitud está integrado en el proceso de control de fabricación de una plancha de acero caliente “al rojo vivo” en la industria del acero. El objetivo del sistema es calcular los grados de superficie plana para cada plancha de acero. Esto se realiza comparando la longitud del perfil lateral con la longitud central. Las imágenes de la plancha de acero son tomadas en condiciones de alta temperatura del acero y alta velocidad de avance de la plancha. Dado este entorno de inspección se requiere tomar imágenes cada 2 mseg. en cinco puntos diferentes. Los datos se procesan en tiempo real de la aplicación, para calcular los valores de desplazamiento de altura de la plancha de acero. Estos valores permiten posteriormente el cálculo de la planitud de la plancha de acero. El método de medida desarrollado por [Garcia et al., 1999] introduce una geometría innovadora en la disposición de los elementos ópticos. Con esta geometría se incrementa el rango de medida sin reducir la precisión. La figura 1.2 muestra un prototipo de laboratorio de este sistema de inspección y la figura 1.3 el lugar donde se implementa el sistema final. Se puede deducir a partir de esta imagen las dificultades del entorno de inspección. La situación concreta de este

caso es común a los sistemas de inspección industrial ad-hoc [Derganc et al., 2003], [Whelan et al., 2001], así los sistemas de inspección industriales deben ser robustos y han de estar preparados para operar en condiciones extremas marcadas por cada entorno de inspección.

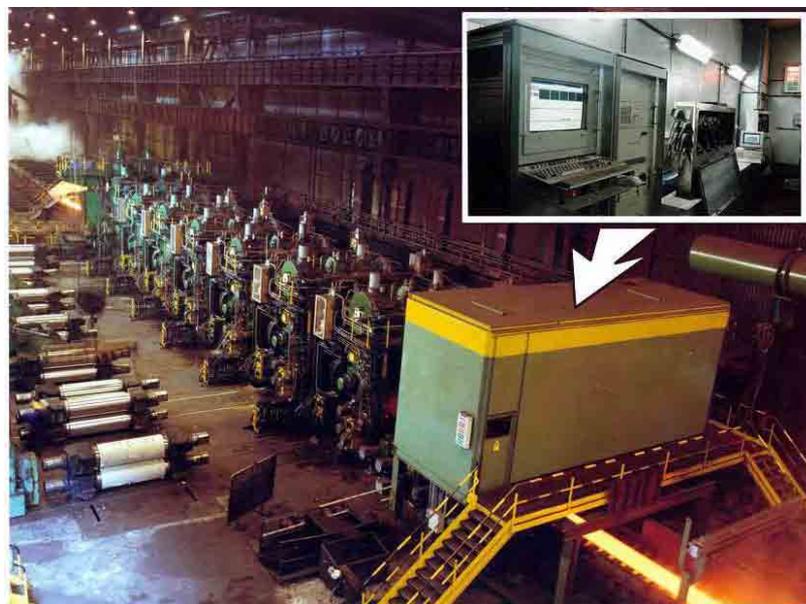


**Figura 1.1:** Representación del sistema para medida de planitud [Garcia et al., 1999]

Los sistemas de inspección desarrollados en los últimos años abarcan todo tipo de aplicaciones, por ejemplo: inspección textil [Tobin et al., 2000], inspección de tubérculos [Noordam et al., 2000], inspección de filtros de gasolina [Lahajnar & Kovacic, 2000], etc. Otra aplicación de inspección metalúrgica la encontramos en [Meriaudeau & C., 2000] donde a través de un repaso a la literatura existente, se presenta las diferentes etapas de un sistema de visión por computador en la industria del acero.



**Figura 1.2:** Sistema de inspección de planitud en el laboratorio [Garcia et al., 1999]



**Figura 1.3:** Sistema de inspección de planitud, integrado en el entorno real de fabricación de acero [Garcia et al., 1999]

En el desarrollo de un sistema de visión industrial por computador hay que tener en cuenta los siguientes apartados [Malamas et al., 2003]:

- El ordenador para procesar las imágenes adquiridas debe ser industrial. Normalmente, se utilizan algoritmos concretos diseñados especialmente para la aplicación industrial. Dicho software básicamente se compone de análisis y clasificación de la imagen.
- Las imágenes se adquieren por una o más cámaras (sensor lineal o sensor bidimensional), situadas en la posición optima de inspección. Una correcta disposición de la cámara o conjunto de cámaras permite obtener imágenes de alta calidad, que posteriormente reducen la complejidad de los algoritmos de procesado de imagen. La posición de las cámaras es normalmente fija debido a que en la fase de diseño del sistema de inspección, el objetivo es solucionar el problema dado y no se contempla su reutilización. Los sistemas automáticos industriales se diseñan para inspeccionar solamente posiciones fijas de objetos conocidos. En ocasiones, los sistemas de inspección fijos diseñados para un problema concreto, necesitan ser calibrados de nuevo debido a pequeñas variaciones en el entorno de inspección. Es normal, por ejemplo, en la industria del acero inoxidable que el entorno de inspección varié de un día para otro debido a reparaciones, mantenimiento o cualquier otro tipo de averías.
- La iluminación es un pilar fundamental de los sistemas industriales de visión por computador. La escena es apropiadamente iluminada y dispuesta para facilitar la captura de la imagen, y obtener las características adecuadas de la imagen para el procesado y clasificación de la imagen. Normalmente, estas características se conocen por adelantado. De esta forma, unas buenas imágenes, bien iluminadas, facilitan el trabajo posterior, al igual, que la correcta disposición de las cámaras como se comento anteriormente.
- Las aplicaciones que poseen procesos con tiempo limitado de ejecución o carga

computacional elevada, suelen exceder las capacidades de procesamiento del procesador principal. Debido a este problema, se puede utilizar hardware específico para aplicaciones concretas del sistema de inspección. Los recursos hardware, más utilizados, complementarios a la aplicación principal son los siguientes:

- Aplicaciones de hardware específico diseñadas en DSP (Digital Signal Processors). Normalmente, se programan para una única tarea, pero se pueden reprogramar para realizar nuevas tareas.
- Aplicaciones de hardware específico diseñadas en circuitos integrados, dedicados a una única tarea (ASIC (Application Specific Integrated Circuit)).
- Aplicaciones de hardware específico diseñadas en FPGA (Field Programmable Gate Array).

La utilización de hardware adicional ayuda a aliviar el problema de la velocidad de procesamiento. En un entorno industrial la velocidad de procesamiento o el funcionamiento en tiempo real, es un “cuello de botella” que requiere elementos hardware complementarios, para realizar eficazmente la tarea de inspección industrial. Así, en [Arias-Estrada & Torres-Huitzil, 2000] se presenta una arquitectura hardware para la implementación de algoritmos basados en convolución. El cálculo de la convolución se realiza en tiempo-real, de una máscara y una imagen. La arquitectura se plantea para lograr, un rápido procesamiento de imagen de bajo nivel. El diseño está basado en una FPGA, la cual dispone de registros para implementar un módulo eficiente y compacto, que calcula las convoluciones. La arquitectura está diseñada para minimizar el número de accesos a la memoria que contiene la imagen capturada. La posibilidad de implementar algoritmos de bajo nivel en tiempo real, sugiere el diseño de sistemas de visión compactos para aplicaciones industriales. Un sensor acoplado a un procesador dedicado únicamente al procesamiento de imagen, puede transmitir información preprocesada al ordenador principal. Simplificando, la carga

computacional del procesador central.

En esta línea [Lecerf et al., 2000] integra en una cámara un sistema compuesto por un sensor de imagen CMOS (Complementary Metal Oxide Semiconductor), una FPGA, dos bancos de memoria y un PC embebido para las comunicaciones y tareas de control.

En [Lehotsky, 2000] se presenta una cámara, basada en CCD lineal, de alto rendimiento y alta sensibilidad para uso en sistemas industriales de visión por computador. La cámara incorpora un microcontrolador embebido y varios PLD (Programmable Logic Device). La combinación microcontrolador-PLD procesan y analizan las imágenes en la propia cámara y permiten al ordenador principal controlar la adquisición, el procesado y el análisis de la imagen. El usuario del sistema tiene control sobre los parámetros de los algoritmos, con el objetivo de calibrar al sistema para una óptima inspección. Los algoritmos implementados son una umbralización estática y otra adaptable.

Los resultados obtenidos por un sistema de visión industrial por computador, pueden ser usados para:

- Control de un proceso de fabricación in situ, sin comunicar los datos hacia el exterior. Por ejemplo, guiar los brazos de un robot para situar componentes electrónicos en una tarjeta de circuitos impresos, pintar superficies, etc.
- Propagación de los datos hacia otros dispositivos externos (Ej.: a través de una red “ethernet” o una interfaz “FireWire”). Con el objetivo de procesar, analizar, clasificar y almacenar datos que provengan de diferentes puntos de inspección.
- Caracterización de defectos en productos para posteriormente realizar informes, corregir los defectos y reemplazar o eliminar partes defectuosas de la línea de producción. Por ejemplo, en la industria del acero inoxidable se realizan informes de los defectos superficiales encontrados en bobinas de 500 metros; se

corrigen los defectos encontrados en una bobina, volviendo a procesarla para eliminar los defectos superficiales; y se eliminan las partes defectuosas cortando el trozo de la bobina que posee el defecto.

Este conjunto de acciones llevadas a cabo en una línea de producción, se engloban en el concepto de “Control de Calidad” del producto a fabricar. El concepto es de suma importancia en la industria y marca la diferencia de un producto en el mercado globalizado.

A partir de los comentarios anteriores se puede observar que la estructura de un sistema de visión industrial puede variar en función de determinados parámetros de configuración que caracterizan el diseño y desarrollo óptimo. Los parámetros se seleccionan en función de los requisitos impuestos por la aplicación específica. De tal manera en [Malamas et al., 2003], se establece que:

“los requisitos para el diseño y desarrollo de un sistema de visión industrial por computador varían dependiendo del dominio de la aplicación, y están asociados a las tareas que realiza el sistema, entorno, velocidad, etc. Por ejemplo, en aplicaciones de inspección mediante visión industrial por computador, un sistema debe de ser capaz de diferenciar entre variaciones/defectos aceptables e inaceptables; mientras que en otras aplicaciones, el sistema deberá de facilitar al usuario las tareas de guiado y alineación, medida, verificación de ensamblado, etc.”.

Este ejemplo, demasiado restrictivo por tratarse de aplicaciones muy diferentes pone de manifiesto la necesidad de sistemas dinámicos capaces de adaptarse a diferentes aplicaciones. Actualmente, no existen sistemas generales de visión industrial que sean capaces de solucionar las tareas propias de cada campo de aplicación. Únicamente se dispone de sistemas diseñados por expertos en los que una vez especificados los requisitos propios de un dominio de aplicación particular, se toman las decisiones apropiadas para el diseño y desarrollo de la aplicación. Por tanto, la especificación de los requisitos juega uno de los papeles más importantes en la tarea de diseño-configuración de un sistema. Esta idea se desarrollará en el capítulo 5, de-

dicado a una nueva arquitectura dinámica que analiza en el nivel del conocimiento el problema de inspección de superficies.

Por otro lado, para la automatización de una tarea de un sistema de visión industrial se necesita conocer que clase de información va a utilizar el sistema de visión y como se puede obtener la información, a partir de medidas o características extraídas de la imagen, requisitos, etc. El objetivo final en automatización industrial es la toma de decisiones en función de la información adquirida.

Finalmente, comentar la importancia de la fiabilidad y robustez en los sistemas de visión industrial:

- La fiabilidad de un sistema se basa en minimizar los “falsos positivos” y “falsos negativos”. Es decir, no aceptar casos que han sido clasificados como óptimos porque realmente poseen defectos y aceptar casos que han sido clasificados como defectuosos porque realmente no poseen defectos. La responsabilidad software de mantener la fiabilidad del sistema recae sobre las etapas de procesado y clasificación. Por otro lado, es importante puntualizar que la responsabilidad hardware juega un papel decisivo en un sistema industrial. La degradación de alguno de sus componentes, por ejemplo la iluminación, conducirá a obtener imágenes de baja calidad. Este problema, normalmente, se intenta solucionar ajustando eficientemente los algoritmos de procesado para restaurar la calidad. Pero, difícilmente y costosamente se consigue devolver al estado original. Habitualmente, en la bibliografía se establece que la efectividad de la clasificación depende de la calidad de la imagen adquirida.
- Los sistemas de visión industriales también han de ser robustos. Es decir, deben adaptarse automáticamente y conseguir funcionar correctamente a pesar de irregularidades en la iluminación, marcas engañosas, incertidumbres en ángulos y posiciones, etc. En el estado actual de los sistemas industriales es difícil considerar un grado de robustez óptimo, debido a que se diseñan para funcionar en condiciones muy particulares. Un buen reconocimiento y clasificación sólo

se pueden obtener bajo unas condiciones óptimas de iluminación y bajo ruido. Así, pequeñas variaciones pueden fácilmente desajustar un sistema.

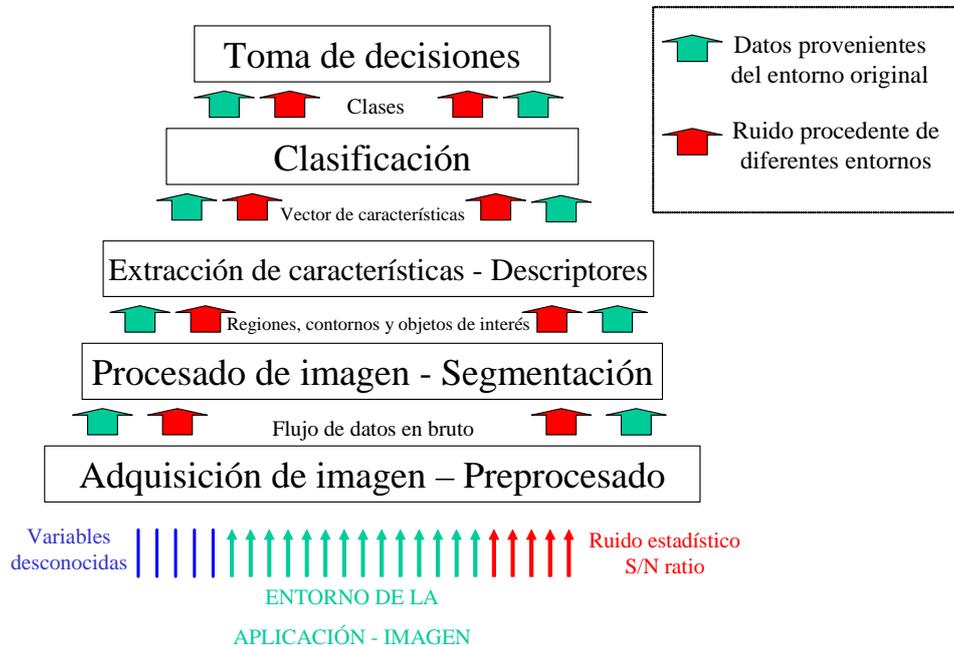
Por último, resaltar que los sistemas industriales de visión por computador deben de ser rápidos (trabajar en tiempo-real marcado por la aplicación particular) y económicamente viables.

### 1.4.1. Etapas en un sistema de visión industrial

Los atributos deseables en un sistema de visión industrial por computador para inspección son flexibilidad, funcionamiento eficiente, adaptación al tiempo-real de la aplicación, coste competitivo, fiabilidad y robustez. Para lograr un sistema con estos atributos y mantenerlos a lo largo de la vida útil del sistema, hace falta definir claramente el espacio de trabajo. Compuesto por las entradas disponibles, la información y conocimiento del dominio, y las salidas deseadas. Típicamente, un sistema para inspección industrial obtiene información de la superficie a través de una imagen digital, que contiene gran cantidad de información pero sin extraer para un computador. Las etapas en una arquitectura de visión para percepción que extraen la información de la imagen y permiten mostrar los resultados de salida deseables, las mostramos en la figura 1.4 (se intenta hacer computable o emular el procesamiento natural humano). En la figura las flechas verdes indican el flujo de información o datos propios de la aplicación para la cual fue diseñado el sistema de visión industrial. En el caso de utilizar el mismo sistema pero variar la aplicación; aparecen las flechas verdes propias de la nueva aplicación y las flechas rojas que representan el nuevo flujo de información o datos que se puede producir al variar la aplicación (entorno de inspección).

En la bibliografía encontramos múltiples definiciones de las etapas de un sistema de visión industrial por computador. Por ejemplo, en [Malamas et al., 2003] se definen 4 etapas para un sistema de inspección industrial:

### Arquitectura de visión para percepción



**Figura 1.4:** Etapas en una arquitectura de visión para percepción

1. Adquisición de la imagen. Las imágenes contienen la información requerida para detectar los posibles defectos en las superficies inspeccionadas. La información se obtiene comúnmente a través de cámaras o cualquier otro dispositivo que transforme la información superficial a inspeccionar en formato digital.
2. Procesado de la imagen. Una vez las imágenes han sido adquiridas y se encuentran en formato digital en el computador, se filtran para eliminar el ruido de fondo o reflexiones no deseadas del sistema de iluminación. También se puede intentar recuperar la calidad de la imagen, si se han introducido distorsiones por el sistema de inspección. Por ejemplo, se pueden corregir las distorsiones geométricas introducidas por la óptica de la cámara.
3. Extracción de características. El conjunto de características describen la ima-

gen de entrada. En esta etapa se calculan un conjunto de características conocidas para el dominio de la aplicación de inspección concreta. Además, hay que poner especial atención para que las características no se superpongan o correlacionen, con el objetivo de obtener mejores resultados de clasificación. Algunas de las características más comunes son el tamaño, la posición, la medida del contorno aplicando detección de borde y las medidas de textura en regiones.

4. Toma de decisiones. Las variables de las características iniciales se combinan para formar un nuevo conjunto de variables más pequeño. De esta forma se reducen las características que describen la imagen. El primer paso es intentar reducir la dimensionalidad del espacio de características de entrada a la dimensionalidad propia del problema. Posteriormente, el conjunto de características reducido se utiliza para tomar una decisión.

Como se ha comentado anteriormente los descriptores y las decisiones tomadas, dependen fuertemente de la aplicación. Por ejemplo, en el caso de inspección visual en línea de producción; el sistema decide si las partes producidas cumplen los estándares de calidad comparando los descriptores calculados con un modelo conocido de la imagen (región u objeto).

En este nivel de toma de decisiones y coincidencia de modelos, los autores diferencian dos tipos de modelos de imagen: declarativo y de procedimiento. El primero consta de restricciones en las propiedades de los píxeles, objetos o regiones, y en sus relaciones. El segundo, se define en términos de procesos que reconocen las imágenes. Ambos modelos pueden ser borrosos o estadísticos que implican restricciones y control sobre las reglas sintácticas. Otra categoría especial de modelos está basada en redes neuronales. Por otro lado, los modelos basados en aproximaciones requieren que las descripciones de la imagen en diferentes niveles coincidan con algún modelo de clases diferentes de imágenes. Esta tarea puede llegar a ser bastante difícil y de computación costosa, si los

modelos son complejos y si se consideran un gran número de modelos. Otra alternativa sería una metodología “arriba-abajo” para coincidencia de modelos. Un modelo se encarga de guiar la generación de descripciones apropiadas de la imagen; mejor que primero generar la descripción y posteriormente intentar que coincida con un modelo.

En otro trabajo, orientado a sistemas industriales de procesamiento de imagen [Demant et al., 1999]; la tarea principal (por ejemplo, inspección de superficies) de un sistema de visión industrial es frecuentemente subdividida en varias etapas independientes, que marcan la estrategia para conseguir el objetivo marcado (por ejemplo, control de calidad). Las etapas individuales siguen el siguiente modelo:

1. Captura de la imagen. Se capturan una o varias imágenes en función de la aplicación.
2. Preprocesado de la imagen. En ocasiones las imágenes no poseen calidad apropiada para el tratamiento directo; entonces, requieren preprocesado de la imagen original, para cambiar ciertas propiedades de la imagen (ej. realzar el contraste, eliminar ruido, destacar estructuras específicas de la imagen, etc.).
3. Definición de una o varias regiones de interés en la imagen de forma manual. En ocasiones, para una aplicación específica, el inspector de línea o experto de la aplicación conocen las áreas de la imagen que han de ser analizadas por el sistema de visión industrial. Así, fácilmente gracias a su conocimiento, pueden ayudar al sistema marcando manualmente sobre la imagen las regiones de interés (“ROI”). Las regiones de interés también pueden comprender la imagen entera, pero es usual encontrar determinadas zonas de la imagen propias del problema de la aplicación (ej. en inspección de acero inoxidable, las regiones de interés contienen manchas de cascarilla (óxido residual) sobre la superficie). Es obvio, que limitar el análisis de imagen a las áreas de interés de la imagen sirve para acelerar el procesamiento, reducir la carga computacional del sistema, e

incrementar la flexibilidad debido a que se puede tratar cada área de forma diferente en función de sus características (ej. se pueden buscar simultáneamente objetos claros y oscuros, seleccionando parámetros individuales para cada área de la imagen).

4. Segmentación de los objetos. Esta etapa fundamental de un sistema de visión industrial, consiste en aislar ciertos objetos presentes en la imagen. La segmentación juega un papel muy importante en los sistemas de visión industrial por computador.
5. Cálculo de las características de los objetos. Después de segmentar correctamente la imagen, se calculan las propiedades características de los objetos, que se reflejan en forma de vector denominado “vector de características”. Las características más comunes son: área, perímetro, posición, orientación, distancia entre objetos, grado de similitud con patrones definidos previamente, etc.
6. Toma de decisión de la exactitud de los objetos segmentados. Finalmente, se comprueban las propiedades características de los objetos con los valores óptimos de la tarea de inspección.

También comentan que en determinados casos especiales, las aplicaciones no requieren segmentación. Por ejemplo, en ciertas inspecciones de superficies, simplemente se necesita evaluar las características globales de una región de la imagen (ej. distribución de brillo o luminosidad). En este caso, las propiedades características se pueden calcular directamente a partir de una región de interés definida manualmente. Este enfoque inusual permite gran flexibilidad.

Finalmente, resaltar que las estrategias llevadas a cabo en cada etapa de un sistema de visión industrial por computador, se simplifican si las imágenes se adquieren bajo condiciones buenas de iluminación y bajo ruido. Con estas condiciones óptimas, se pueden diseñar descriptores de imagen y modelos de clases sencillos; en vez de

TIPO DE INSPECCIÓN	AUTORES	DESCRIPCIÓN
Inspección automática de circuitos impresos	[Moganti et al., 1996]	Técnicas y algoritmos para inspección automática de tarjetas de circuitos impresos
Inspección de calidad de madera	[Bhandarkar et al., 1999]	Detección y clasificación de defectos internos en troncos de árbol
Inspección automática de fruta	[Jiménez et al., 1999]	Sistema para reconocimiento automático de fruta
Inspección de planitud en acero	[Garcia et al., 1999]	Sistema de inspección de planitud en tiempo-real, para líneas de producción de barras de acero
Inspección textil	[Conci & Belmiro, 2002], [Hou et al., 2005], [Stojanovic et al., 2001]	Aplicación-sistema de inspección, método para detección de defectos y sistema automático para control de calidad
Inspección visual automática en general	[Chin, 1988], [Newman & Jain, 1995], [Eduardo, 1993a] [Eduardo, 1993b]	Inspección visual mediante aproximaciones basadas en modelo y
Revisión bibliográfica general	[Rosenfeld, 2000a], [Rosenfeld, 2001]	Clasificación de literatura relacionada con visión por computador y análisis de imagen

**Tabla 1.1:** Análisis de algunas de las revisiones o recopilaciones mas relevantes en el ámbito de las aplicaciones de inspección mediante sistemas de visión industrial por computador

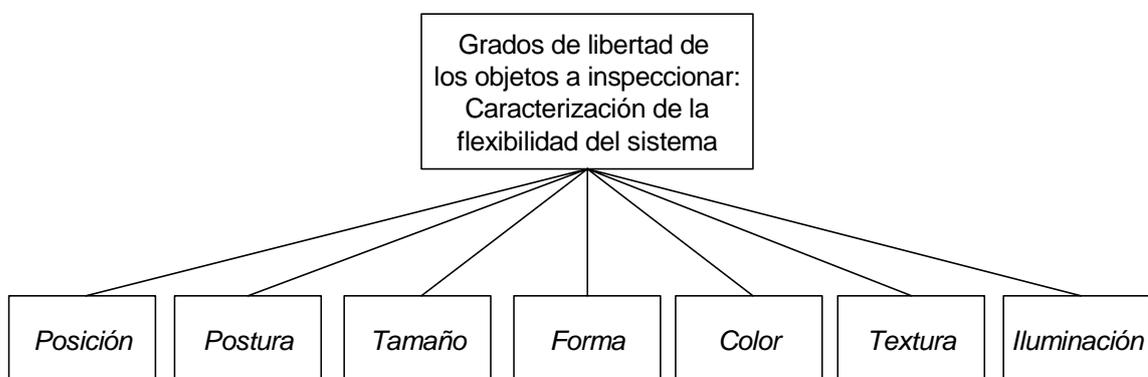
modelos complejos y de computación costosa.

### 1.4.2. Aplicaciones de inspección con sistemas de visión industrial

En los últimos años se han realizado revisiones y trabajos especializados en determinados campos de aplicación. Algunas de las más importantes sobre inspección se recogen en la tabla 1.1.

Por ejemplo, las aplicaciones de visión industrial se pueden clasificar basándose en las características que va a inspeccionar el sistema (ej. la forma) y que cuyas medidas

no afectan al proceso de inspección (por ejemplo, es indiferente la forma que tenga un defecto, el sistema puede inspeccionar todas las formas del defecto). Esto permite al sistema ser independiente, según el caso, de algunas características (ej. la forma) del defecto a inspeccionar. Este conjunto de características define los grados de libertad del proceso de inspección. Los grados de libertad más comunes en el entorno industrial se muestran en la figura 1.5 y son: la forma, las dimensiones geométricas, la intensidad, la textura, la postura, etc. (ej. en los sistemas de inspección de laminados metálicos, la posición u orientación de manchas de oxido superficial son dos grados de libertad). Los grados de libertad de los objetos a inspeccionar por el sistema se consideran una medida de la flexibilidad del sistema de visión industrial por computador. Pocos grados de libertad implican mayor dependencia del sistema de inspección con la aplicación para la cual fue originalmente diseñado. (ej. un sistema con los grados de libertad de posición, tamaño, forma, orientación, etc. se podrá adaptar a inspeccionar defectos superficiales en distintos tipos de materiales. Estos grados de libertad se contemplarán, más adelante, en el diseño de la arquitectura dinámica para inspección de superficies ARDIS).



**Figura 1.5:** Principales grados de libertad de los sistemas de visión industrial

Por lo tanto, los sistemas con pocos grados de libertad son menos ampliables. Esto redundaría en los costes de los sistemas industriales de visión debido a que sólo se diseñan para una aplicación particular y quedan totalmente inservibles para aplica-

ciones de otro tipo o simplemente para la misma aplicación pero diferente material a inspeccionar. Por otro lado, altos niveles de variabilidad son difíciles de conseguir y son característicos de sistemas generales o ampliables. Para lograr la mayor cantidad posible de grados de libertad, el sistema debe de emplear sofisticados algoritmos de clasificación de la imagen y minimizar su dependencia con el objeto inspeccionado y sus posibles deformaciones. Por ejemplo, un sistema se puede mejorar para detectar nuevos tipos de defectos si se añaden funciones de análisis y procesado de imagen adicionales, se introducen en el sistema y aplican independientemente de las que ya existían en el sistema original. De esta forma se consiguen más características de la imagen; y por ejemplo, si el sistema originalmente sólo detectaba defectos superficiales de un tipo, ahora puede ser capaz de detectar defectos de otra clase totalmente diferente (por ejemplo, defectos de cascarilla residual en acero inoxidable [Martín et al., 2003b], defectos de nudos en madera [Silvén et al., 2003], entre otros). Éste será uno de los objetivos de la arquitectura ARDIS (Arquitectura dinámica para Inspección Visual de Superficies, capítulo 5). Esta clasificación pone de manifiesto la necesidad de buscar equilibrio entre flexibilidad, complejidad y coste en el diseño de sistemas de inspección industriales.

La tabla 1.2 [Malamas et al., 2003] muestra varios sistemas reales de visión industrial para inspección de calidad de superficies y sus grados de libertad correspondientes. Algunas aplicaciones se centran en la inspección de una única característica (ej. la iluminación). El resto de características se consideran grados de libertad para esa aplicación, indicando la flexibilidad del sistema de visión industrial. Pero no todas son igual de importantes, así pues, cada aplicación requerirá sus características óptimas.

## **1.5. Inspección Industrial de superficies**

Este apartado se centra en los sistemas de visión industrial por computador para inspección de superficies. El espacio de trabajo de esta tesis está acotado a los

Autores	Campo de aplicación	Grados de libertad
[Sanches & Piedade, 1997]	Pintado de pequeñas resistencias	Orientación de la resistencia
[Miller et al., 1996]	Fundición de planchas de aluminio	Ancho de la plancha
[Khandogin et al., 1997]	Inspección de raíles de ferrocarril	Iluminación/posición del rail
[Jiang & Jiang, 1998]	Juntas de aceite	Iluminación
[Li & Lin, 1994]	Inspección superficial de obleas	Deformación / escala / orientación / posición
[Lacey et al., 1998]	Aproximación superficial	Iluminación
[Shafarenko et al., 1997]	Inspección superficial de granito	Textura
[Tsai & Hsieh, 1999]	Textura direccional	Iluminación / rotación
[Tsai et al., 1998]	Aspereza superficial	Orientación
[Smith et al., 1999]	Defectos superficiales	Postura
[Bahlmann et al., 1999]	Defectos en costuras textiles	Traslación/rotación
[Bhandarkar et al., 1999]	Defectos internos en madera	Densidad de madera
[Drake & Packianather, 1998], [Packianathe & Park, 2000]	Superficie contrachapada de madera	Escala/Intensidad
[Boyer & Ozguner, 2001]	Corrosión superficial	Forma

**Tabla 1.2:** Sistemas reales de visión industrial para inspección de calidad superficial y sus grados de libertad correspondientes

sistemas de inspección de superficies y la solución de la tarea compleja de diseño-configuración de inspección de superficies. Por tanto, se presentan los conceptos relacionados con la inspección industrial de superficies mediante visión por computador y se revisan varios trabajos en detección de defectos superficiales para control de calidad de superficies.

La investigación y desarrollo de sistemas modernos de inspección de superficies en la industria se puede catalogar en las siguientes clases: inspección de la calidad superficial del material e inspección dimensional del defecto superficial. En la tabla 1.3 se reúnen las clases de defectos superficiales más comunes y algunas de las características que caracterizan a dichos defectos [Smith, 2001].

La solución al problema de inspección de superficies se reduce a cumplir los estándares de calidad del producto fabricado. La clase solución define el control de calidad del material producido y suele ser binaria “pasa/no pasa”. La inspección de arañazos,

---

Tipos de defectos. Inspección de calidad superficial	Manchas, agujeros, hoyos, ranuras, arañazos, grietas, desgates, acabados, asperezas, texturas, juntas (ej. soldaduras en bobinas de acero inoxidable), continuidad, polvo, virutas, etc.
Características. Inspección dimensional del defecto superficial	Dimensiones, forma, posicionamiento, orientación, alineación, redondez, esquinas, etc.

---

**Tabla 1.3:** Tipos y características de defectos superficiales en inspección industrial

grietas, hoyos, zonas desgastadas, acabados correctos, asperezas, texturas, etc. son tareas típicas de inspección de calidad de superficies (ej. inspección de calidad superficial en laminados metálicos). Los defectos superficiales de oxido en planchas de acero inoxidable forman parte de esta clase de defectos y serán ampliamente estudiadas a lo largo de esta tesis [Martín et al., 2003b], [Martín et al., 2003c]. Los sistemas de visión industrial para inspección de superficies se pueden encontrar principalmente en la industria textil, maderera y metalúrgica. Las aplicaciones más importantes son detección de defectos y control de calidad. Por ejemplo en [Smith et al., 1999] se proponen varias técnicas de segmentación para la detección de defectos superficiales (ej. hendiduras, protuberancia, etc.). Otra tarea de los sistemas de visión en inspección industrial de superficies, es comprobar si las dimensiones de un defecto superficial están dentro de las tolerancias especificadas por el sistema.

En la industria textil, por ejemplo en [Bahlmann et al., 1999], se evalúa la calidad de costuras textiles usando clasificación basada en redes neuronales auto-organizadas. El sistema también permite comparar la inspección realizada por el sistema con la del inspector de línea. Primero se localizan las costuras en imágenes de bajo contraste y posteriormente se inspecciona manualmente la curvatura ondulada de las costuras, para verificar el correcto funcionamiento del sistema de inspección.

Por otro lado en inspección de madera, CATALOG [Bhandarkar et al., 1999] es un sistema para detección de defectos en troncos de madera (en el plano superficial de corte) mediante tomografía axial computarizada (TAC). Se adquieren secuencias de trozos de la imagen TAC y cada uno es segmentado en regiones bidimensionales.

Cada trozo de imagen segmentada se analiza y caracteriza como “sin defecto” o “con defecto”. En otro caso, [Drake & Packianather, 1998] se muestra que el uso de un árbol de decisión en combinación con una topología de red neuronal modular es más eficiente que una única red neuronal para la clasificación de contrachapado de madera. El diseño de esta topología se basa en normalizar la variación entre clases de características. Una versión mejorada de esta topología [Packianathe & Park, 2000] se basa en la variación dentro de las clases de características. Esto permite reducción de la complejidad de la topología de la red neuronal y como consecuencia se mejora la precisión de la clasificación.

En el caso de industria metalúrgica, por ejemplo, nos encontramos con la inspección de superficie que se realiza en el proceso de fundición de planchas de aluminio. Donde se usan medidas de temperatura infrarroja que proporcionan una medida de la distribución de temperatura superficial para evaluar la calidad de las planchas de aluminio. La inspección de planchas de aluminio se desarrolla en un proceso de dos niveles [Miller et al., 1996]. Primero el sistema inspecciona ambos lados de una plancha de aluminio y captura imágenes de posibles regiones con defectos. Segundo, las imágenes se clasifican en función del tipo de defecto y almacenan para que posteriormente las revisen los expertos.

También nos encontramos con inspecciones superficiales menos frecuentes como, por ejemplo, la evaluación de la aspereza superficial en piezas mecanizadas que se trata en [Tsai et al., 1998]. Primero se aplica la transformada de Fourier para extraer las medidas de aspereza. Posteriormente se emplean redes neuronales para la clasificación de las superficies que poseen distintas clases de asperezas. Otro caso es la inspección de defectos en objetos con superficies que poseen texturas direccionales (ej. madera natural, superficies mecanizadas, tejidos textiles, etc.) que se investiga en [Tsai & Hsieh, 1999]. En este caso, se aplica una mejora global de la imagen basándose en la transformada de Fourier. Las componentes de alta frecuencia que corresponden a patrones lineales se discriminan de las componentes de baja frecuencia que corresponden a las regiones con defectos. Una propuesta alternati-

va para la inspección de imágenes en color con texturas aleatorias se presenta en [Shafarenko et al., 1997]. Este método considera propiedades de la imagen relativas a la textura y al color, e introduce una medida de la similitud del color que permite la utilización de la transformada de línea divisoria de aguas (más conocida como transformada “watershed”).

Así pues, una vez revisados los sistemas de inspección visual en la industria, a continuación, se comentan las arquitecturas y estrategia llevadas a cabo en el diseño y desarrollo de un sistema de inspección visual por computador.

## Capítulo 2

# Arquitecturas para inspección visual industrial en tiempo-real

En este capítulo revisaremos los conceptos y bibliografía relacionados con las arquitecturas de inspección visual en la industria y se motiva el trabajo hacia la necesidad de una arquitectura dinámica para inspección de superficies. Es decir, la evolución de las arquitecturas estáticas a las arquitecturas dinámicas en la industria.

La tarea de inspección visual de superficies es una tarea compleja que requiere una estrategia y organización de etapas (por ejemplo, segmentación, descripción, etc.), métodos (por ejemplo, filtrar-y-umbralizar, etc.) y técnicas de visión artificial (detección de bordes, clasificación de defectos mediante redes neuronales, etc.) para su solución. En general, las tareas de visión por computador necesitan una estrategia compleja de métodos y técnicas de visión artificial que permiten solucionar el problema de visión planteado [Rincón et al., 2005b], [Rincón et al., 2005a]. Por lo tanto, utilizamos el término arquitectura para englobar el conjunto de etapas, métodos, técnicas de visión artificial, etc. que nos permiten solucionar un determinado problema de visión industrial por computador para una aplicación específica de inspección de superficies. Una arquitectura clásica o estática engloba la estrategia y organización propuesta por un experto para una aplicación concreta. Por otro lado, arquitectu-

ra dinámica es aquella que puede adaptarse a diferentes entornos, acotados por su conocimiento del dominio, modificando la configuración de un sistema para solucionar, en este caso, una tarea de inspección de superficies. Esto requiere englobar más etapas, métodos especiales, técnicas y conocimiento del dominio que se comentarán en el capítulo relativo a la arquitectura dinámica ARDIS (Arquitectura dinámica para Inspección Visual de Superficies). Una arquitectura dinámica debe permitir diferentes flujos de información y conocimiento para adaptarse automáticamente a diferentes entornos y aplicaciones [Guinea et al., 1991], [Guinea et al., 1993]. De manera general hay que contemplar variaciones en el entorno, fallos en los componentes del sistema de inspección, cambios en los objetivos, diferentes formas de mostrar resultados, cambios en la iluminación exterior, elementos ópticos intercambiables (lentes, filtros interferenciales, . . .), etc.

Normalmente, las arquitecturas de inspección visual se diseñan para resolver tareas específicas de inspección que sólo pueden usarse en situaciones particulares debido a las fuertes restricciones de la aplicación concreta. Así pues, se puede diferenciar entre restricciones físicas como iluminación, posición, distancia de enfoque, etc. y restricciones software como algoritmos de filtrado específicos, segmentación, redes neuronales, etc. En el caso de las arquitecturas dinámicas de inspección, éstas requieren un flujo de información y conocimiento para adaptarse al entorno variable de una aplicación particular o al posible cambio a una nueva aplicación de inspección. Por esta razón, es necesario investigar una metodología robusta para la industria que soporte información (datos) y conocimiento de forma sencilla para el inspector de línea, y a la vez, permita al diseñador o usuario avanzado acceder a los entresijos del sistema para cambiar atributos y conocimiento con el objetivo de adaptar el sistema de inspección. Idealmente en la fase de diseño de una arquitectura dinámica, se debe contemplar la extracción de conocimiento e información de la imagen y del experto para adaptarse automáticamente a las necesidades del entorno y a los requisitos de la aplicación de inspección.

Por otro lado, los sistemas de visión industrial por computador incorporan las

arquitecturas de visión que han sido diseñadas para proveer soluciones óptimas en inspección industrial. Los sistemas, además de la arquitectura de inspección, incorporan los componentes de iluminación, posicionamiento, ajuste, etc. necesarios que se entrelazan con la arquitectura para lograr solucionar el problema de inspección. De esta forma, se mejora la productividad de una industria y el control de calidad, y se proporcionan ventajas frente a sus competidores.

Actualmente, los sistemas usados en inspección industrial se aplican a entornos particulares y poseen arquitecturas rígidas que no pueden adaptarse al entorno o nuevos objetivos o nuevas aplicaciones. Son estructuras estáticas que soportan un flujo de datos muy definido, poseen algoritmos específicos embebidos y presentan resultados por pantalla al usuario de la aplicación en forma de estadísticas. La eficiencia del sistema se basa únicamente en la pericia del diseñador (normalmente poco familiarizado con el entorno industrial y la aplicación concreta de destino) y se limita a utilizar los algoritmos apropiados de procesamiento de imagen, clasificación, etc.; cámaras fijas e iluminación estándar.

La estructura de una arquitectura estática de visión se mostró en el capítulo anterior (figura 1.4). Expertos cualificados requieren información y experiencia de una aplicación concreta para seleccionar los algoritmos apropiados y diseñar la arquitectura. Además, necesitan conocer los componentes del sistema donde posteriormente se integrará la arquitectura de visión. Los componentes físicos poseen parámetros y cualidades que han de encajar con el software desarrollado. Un sistema jerárquico de inspección industrial está formado por las siguientes etapas que soportan desde el gran flujo de datos inicial de la imagen hasta la óptima clasificación de los datos antes de la toma de decisiones: adquisición de la imagen, preprocesado y procesamiento de la imagen, extracción de características, clasificación, interpretación y toma de decisiones. Esta jerarquía de diferentes etapas, donde la información de bajo nivel es condensada progresivamente, muestra una estructura clásica abajo-arriba (“bottom-up”) [Zuech, 2000] de procesamiento de flujo de información. La base de la pirámide (figura 1.4) recibe la imagen (datos en bruto) de la superficie a inspeccionar

y la parte más alta se encarga de la toma de decisiones en función del objetivo fijado. Por ejemplo, en una tarea de inspección de superficies para la toma de decisión de “calidad de la superficie”, se establecen unos rangos de calidad que el experto humano ha fijado previamente. Este control de calidad realizado por el sistema se materializa con la decisión del inspector de línea, que retira el material o deja que continúe en la línea de producción. Así, desde la imagen hacia la toma de decisión, decrece la cantidad de datos e incrementa el significado en el flujo de información. El proceso de percepción condensa el flujo de información desde el entorno hasta el experto, siguiendo normalmente un esquema de reconocimiento de patrones jerárquico abajo-arriba (adquisición de imagen, características, clasificación e interpretación) [Guinea et al., 1997], [Garcia-Alegre et al., 1995]. Por otro lado, los parámetros de los algoritmos son preestablecidos durante el diseño de la arquitectura y no pueden variarse. Por ejemplo, en la fase de preprocesado de la imagen, el experto selecciona los filtros espaciales óptimos y el tamaño de ventana apropiada para eliminar el ruido de la imagen en función de la aplicación concreta.

En el caso de una arquitectura dinámica, los parámetros se deben autoconfigurar. Así en el caso de un filtro espacial, se selecciona el tamaño de ventana apropiado para cada tipo de ruido; que puede variar debido al cambio de material a inspeccionar. Otros ejemplos de reconfiguración dinámica a distintos niveles son:

- Ajuste de parámetros para segmentar óptimamente regiones o bordes en la fase de procesado de la imagen y así obtener mejores vectores de características que permitan clasificar correctamente los defectos.
- Selección, para cada entorno, del conjunto de descriptores esenciales que posteriormente se utilizaran en la clasificación de cada tipo de defecto. Los descriptores pueden ser posición, tamaño, forma, color, textura, intensidad, área, centro de masas, etc. Este conjunto puede ser variable dependiendo del objetivo, del tipo de material a inspeccionar y de los recursos del sistema de inspección.

- La selección del clasificador apropiado, es una de las tareas más delicadas de una arquitectura dinámica. Existen muchos tipos de clasificadores (redes neuronales, clasificadores borrosos, estadísticos, etc.), sin embargo, uno se adaptará mejor que otro a cada tipo de aplicación de inspección (en el apéndice A, se puede consultar una comparación entre dos tipos de clasificadores (Perceptron Multicapa y Mapas Autoorganizados) en inspección de cascarilla residual). Por lo tanto, una arquitectura dinámica debe seleccionar el clasificador conveniente en función del objetivo, error de reconocimiento, tiempo de clasificación, número de ejemplos necesarios para aprendizaje, uso de memoria, etc.

En la bibliografía se encuentran modelos para entender escenas dinámicas [Chella et al., 1997], [Chella et al., 2000] y arquitecturas autoajustables [Shekhar et al., 1999] que ponen de manifiesto la importancia de las arquitecturas dinámicas en los sistemas de visión.

También, hay que puntualizar que los requisitos para el diseño y desarrollo de un correcto sistema de inspección industrial son diferentes dependiendo de las tareas que tiene que realizar. En la actualidad no se conoce ningún sistema industrial que pueda inspeccionar diferentes defectos superficiales en distintos materiales. En concreto, en nuestro caso, esta tesis se ciñe o se limita a la tarea de inspección de superficies de materiales laminados que se fabrican en una línea de producción. Ésta es una limitación de las arquitecturas dinámicas debido a que es difícil diseñarlas para que un sistema de inspección industrial sea capaz de llevar a cabo varias tareas de inspección.

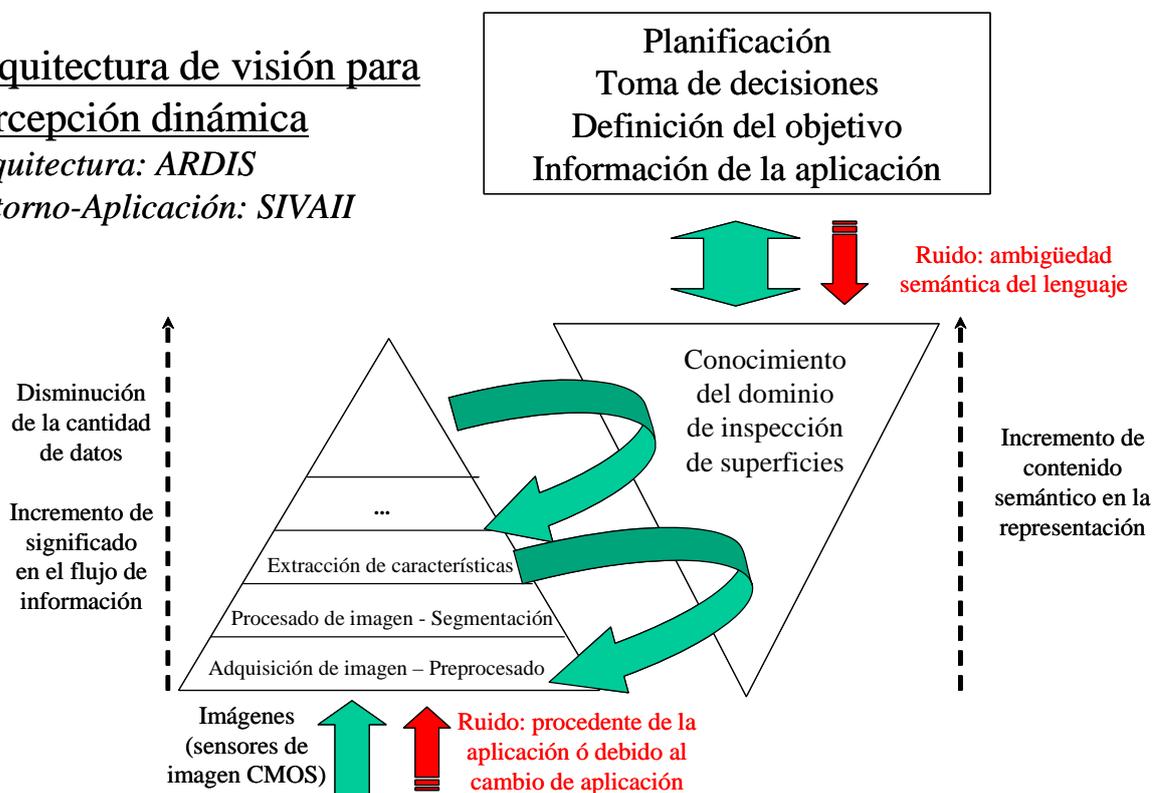
Un esquema inicial de la arquitectura dinámica que se propondrá en esta tesis se muestra en la figura 2.1 y está dotada de distintos módulos que engloban conocimiento e información (datos). Además se incorporará una sencilla interfaz de usuario que permitirá al inspector de línea definir fácilmente los objetivos (requisitos del sistema) y al usuario experto introducir conocimiento del dominio de inspección de superficies. Así cada sistema configurado podrá inspeccionar un material laminado

específico (acero inoxidable, madera, etc.). El conocimiento estático o roles estáticos se encargarán de seleccionar apropiadamente los componentes internos (información dinámica) para lograr la adaptación a diferentes materiales laminados y, por tanto, una detección eficiente de los defectos superficiales y un control de calidad fiable.

## Arquitectura de visión para percepción dinámica

*Arquitectura: ARDIS*

*Entorno-Aplicación: SIVAI*

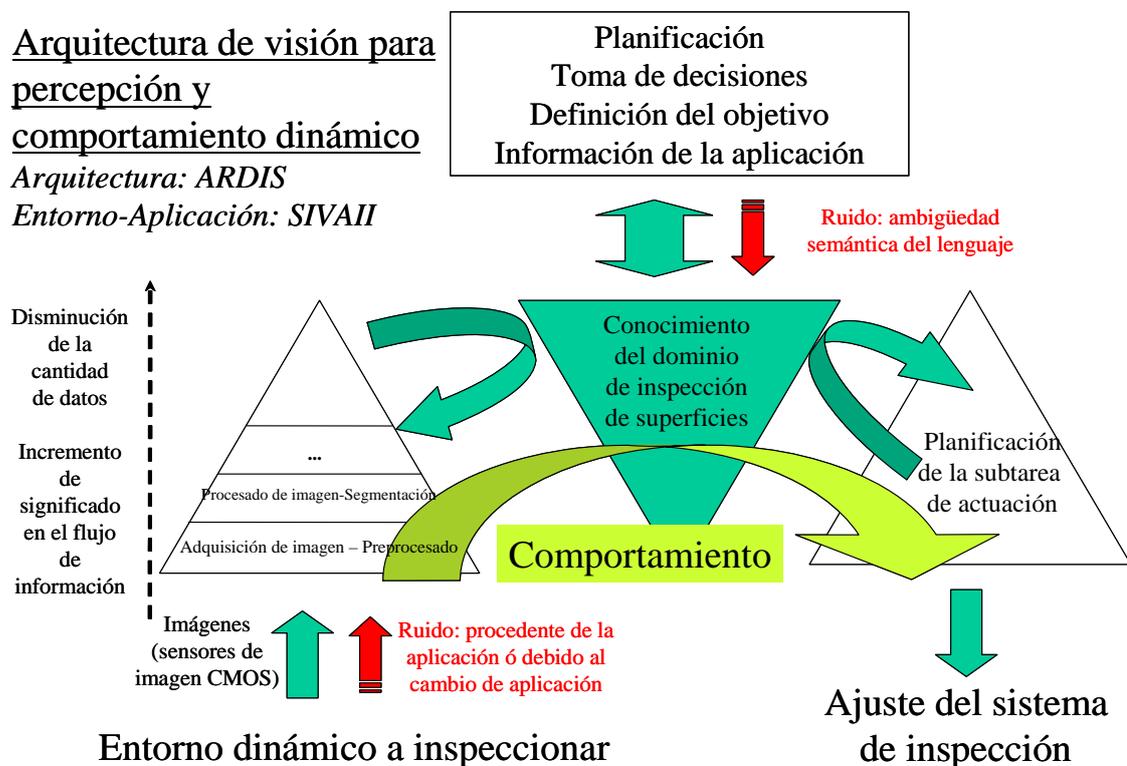


## Entorno dinámico a inspeccionar

**Figura 2.1:** Arquitectura de visión para percepción dinámica (Arquitectura: ARDIS; Entorno-Aplicación: SIVAI)

Por otro lado, un sistema de percepción activa soluciona el problema de variación en el entorno, manteniendo una adaptación dinámica fiable, entre el objetivo de la aplicación y el entorno variable. Por este motivo, la arquitectura dinámica ARDIS permite configurar secuencialmente los componentes de entorno, tiempo-real, control de calidad y técnicas de visión por computador.

En el caso de necesitar actuar sobre el entorno se debe añadir, a la figura anterior, otro módulo de interconexión nuevamente con el entorno (figura 2.2). Así, se consigue un enlace percepción-actuación entre la arquitectura anteriormente descrita y la nueva subtarea de actuación sobre el entorno. Esta estructura de percepción-actuación tiene la ventaja de tomar decisiones de actuación propias, apoyándose en el conocimiento del dominio de inspección de superficies y el objetivo definido por el inspector de línea. Un ejemplo de actuación se muestra en el apéndice A al implementar un ajuste automático de foco.



**Figura 2.2:** Arquitectura de visión para percepción y comportamiento dinámico (Arquitectura: ARDIS; Entorno-Aplicación: SIVAI)

## 2.1. Arquitecturas de visión dinámicas y reconfigurables

Los sistemas de visión por computador deben de ser capaces de configurarse (manual o automáticamente) y asimilar conocimiento para construir una sólida representación interna del entorno exterior. Esta representación interna permite al sistema dibujar interfaces, tomar decisiones, adaptarse al entorno, funcionar en tiempo-real necesario para cada aplicación, seleccionar los algoritmos apropiados para cada tarea de inspección, establecer controles de calidad para cada material, llevar a cabo razonamiento sobre sus propias tareas, entre otras. En el caso que nos ocupa en esta tesis, razonamientos internos sobre la tarea de inspección de superficies.

Los sistemas de visión por computador usados en entornos de operación industriales deben de satisfacer los requisitos opuestos de flexibilidad y conveniencia:

- Flexibilidad es la habilidad para adaptarse a variaciones en condiciones de operación del sistema.
- Conveniencia está relacionado con la facilidad de utilización del sistema por un usuario no familiarizado con los detalles técnicos de los algoritmos de visión artificial empleados por el sistema.

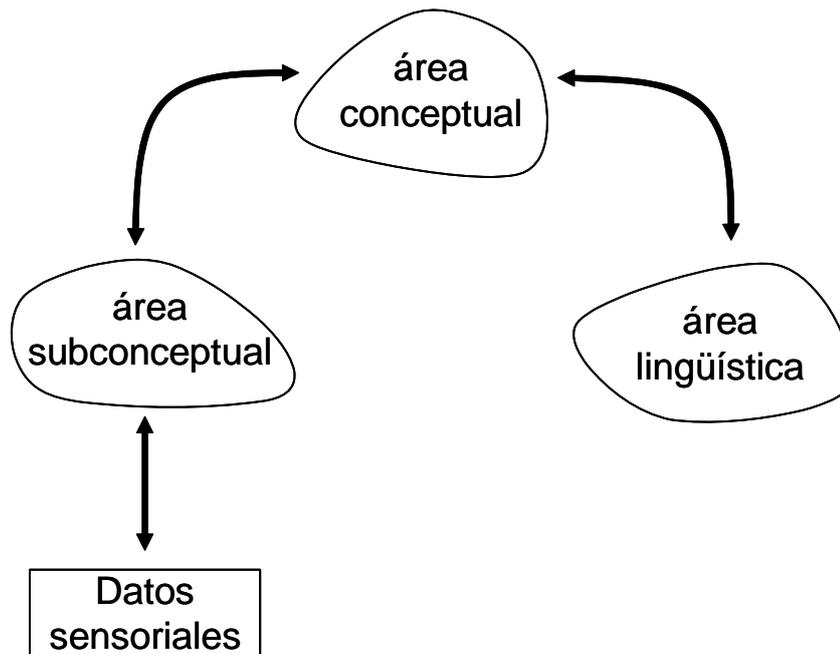
Las variaciones en las características de la imagen se deben a factores como: condiciones de iluminación, propiedades de la superficie a inspeccionar, distancias de inspección, parámetros de adquisición de imagen, etc. Un sistema de visión necesita adaptarse a una cantidad razonable de variaciones y reaccionar rápidamente cuando las características de la imagen se desvíen de las condiciones ideales. Las variaciones se pueden tener en cuenta por el sistema, proporcionando métodos alternativos para cada tarea y ajustando los parámetros para cada método. En bastantes casos, una elección acertada de los métodos y parámetros proporciona resultados de calidad aceptable en un amplio rango de condiciones de operación del sistema.

En el mundo real y actual, los sistemas industriales de visión artificial se utilizan por usuarios expertos en análisis visual de imágenes, pero estos pueden no estar familiarizados con los detalles técnicos de los métodos de visión artificial que utilizan. Por lo tanto, es razonable esperar que el usuario no responda en una situación en la que se requiera realizar selección y ajuste de los métodos y parámetros de la tarea de inspección. Esta función es más apropiada para el diseñador del sistema, que es especialista en visión artificial. Pero normalmente, no está disponible, in situ, durante la operación del sistema. De esta forma, un sistema de visión que proporciona flexibilidad en la elección de los métodos de visión artificial y valores de los parámetros, puede ser poco conveniente para el usuario final que lo va a utilizar [Shekhar et al., 1999].

Con el objetivo de solucionar este problema, en [Chella et al., 1997] se presenta una arquitectura cognitiva (basada en el conocimiento) para un sistema de visión artificial. En la cual se construye una efectiva representación interna del entorno mediante procesos definidos en un nivel intermedio. Este nivel actúa como intermediario entre los datos del sensor y el nivel simbólico. Esta arquitectura no se considera un modelo de visión humana. Sin embargo, los autores utilizan varios resultados cognitivos como fuente de inspiración. Por otro lado, según el modelo de Marr [Marr, 1982] la percepción visual se modela como un proceso, donde información y conocimiento se representan y procesan en diferentes niveles de abstracción; desde el bajo al alto nivel (donde el conocimiento sobre los objetos percibidos es de naturaleza simbólica).

Clásicamente, los sistemas para interpretación de escenas dinámicas poseen una pobre representación intermedia. Así, por ejemplo, en una arquitectura de inspección de superficies, la carencia de una buena representación intermedia limita el flujo de información entre los niveles de análisis de imagen y los requisitos de inspección marcados por el inspector de línea. Por lo tanto, se limita la capacidad de producir descripciones simbólicas satisfactorias de las escenas dinámicas. Una arquitectura para interpretación de escenas dinámicas integra de forma sencilla técnicas de vi-

sión artificial y representación de conocimiento simbólico [Chella et al., 2000]. Esto se consigue introduciendo una buena representación y procesamiento conceptual intermedio que se sitúa entre el conocimiento extraído por los algoritmos de visión artificial y el conocimiento organizado simbólicamente. La arquitectura la organizan en tres áreas computacionales (figura 2.3):



**Figura 2.3:** Tres áreas computacionales de la arquitectura para entendimiento de escenas dinámicas [Chella et al., 2000] y las relaciones entre ellas

- El área subconceptual es relativa al procesamiento de datos procedentes de los sensores. El término subconceptual indica que la información aún no ha sido organizada en términos de estructuras y categorías conceptuales. En el caso de un sistema de inspección industrial mediante visión artificial, esta área incluiría todos los algoritmos y métodos para detectar defectos superficiales.
- En el área lingüística, representación y procesamiento se basan en formalismo lógico.
- El área conceptual es intermedio entre las áreas subconceptual y lingüística.

Los datos se organizan en estructuras conceptuales y son independientes de cualquier descripción lingüística. El formalismo simbólico del área lingüística se interpreta en estas estructuras.

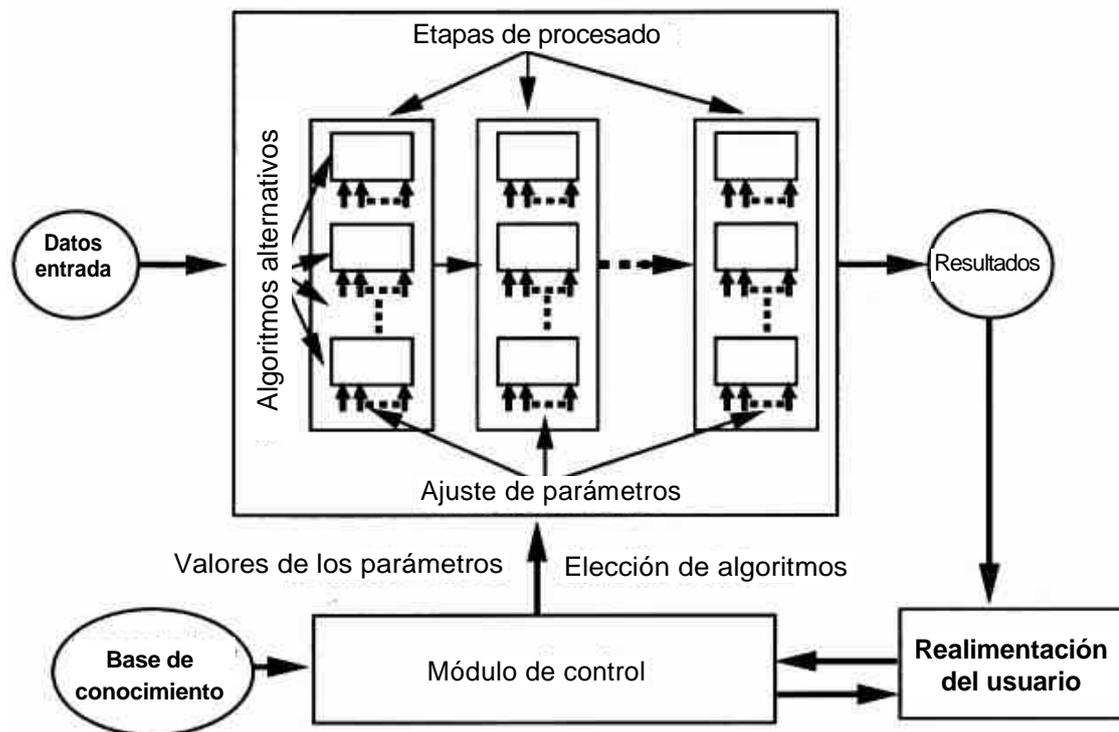
Las tres áreas son componentes de computación simultánea y trabajan al mismo tiempo en diferentes tareas. Además entre ellas, no existen direcciones privilegiadas en el flujo de información. Algunos procesos son estrictamente abajo-arriba, donde el flujo de información va desde el nivel subconceptual al lingüístico, a través del nivel conceptual. Otros procesos combinan arriba-abajo con abajo-arriba. El trazado entre las áreas conceptual y lingüística proporciona la interpretación de los símbolos lingüísticos en términos de estructuras conceptuales.

Por otro lado, los sistemas de visión activa tienen la capacidad de interactuar continuamente con el entorno [Ferruz & Ollero, 2000], [Traver & Pla, 2005], [Ukita & Matsuyama, 2005]. Del mismo modo, esta capacidad, es necesaria en un sistema de inspección de superficies donde el entorno de inspección puede variar. Esto implica reemplazar representaciones estáticas con rutinas visuales que procesen información rápidamente y se adapten al nuevo escenario. En [Rao & Ballard, 1995] se propone una arquitectura de visión activa de propósito general basada en representaciones icónicas, eficientemente calculables. La arquitectura emplea dos rutinas visuales primarias, una para identificar la imagen visual próxima a la fóvea (identificación del objeto) y otra para localizar un prototipo almacenado en la retina (localización del objeto). El diseño permite comportamientos visuales complejos, que se obtienen componiendo estas dos rutinas con parámetros diferentes. Las representaciones icónicas están compuestas de vectores de características de grandes dimensiones. Estos se obtienen a partir de las respuestas de un conjunto de filtros espaciales derivativos Gaussianos para diferentes orientaciones y escalas. Estas representaciones se almacenan en dos memorias separadas. Una memoria está ordenada por las coordenadas de la imagen, mientras que la otra está organizada por las coordenadas de los objetos. En la localización del objeto se compara un conjunto

localizado de características del modelo con características de la imagen en todas las posibles posiciones de la retina. Para la identificación del objeto se compara un conjunto de características de la fovea con todas las posibles características del modelo. Los autores presentan resultados experimentales sobre la implementación de estas rutinas, casi en tiempo-real, en un procesador de imagen paralelo (“pipeline”). También, sugieren estrategias simples para abordar los problemas de oclusiones y variaciones de escala.

Otra arquitectura para sistemas de visión activa en tiempo-real [Fayman et al., 1998] se realiza con un enfoque unificado tolerante a fallos. El sistema se diseña modularmente para añadir hardware y software redundante de forma flexible; y también posibilitar reconfiguración del sistema cuando y donde sea necesario. Esto permite manejar fallos en el contexto de la visión activa. Además, la distribución de software en el hardware disponible, permite a los usuarios utilizar dos modos de ejecución (simulación y prototipado rápido).

Finalmente, comentar un esquema para el desarrollo de sistemas de visión artificial que incorpora junto con los algoritmos de procesamiento de imagen, conocimiento para la solución de problemas; necesario para obtener un funcionamiento óptimo del sistema [Shekhar et al., 1999]. En este enfoque, el usuario proporciona los datos de entrada, especifica las tareas de visión que va a realizar el sistema y proporciona re-alimentación en forma de evaluaciones cualitativas de los resultados obtenidos. Estas valoraciones se interpretan en un esquema basado en el conocimiento para seleccionar automáticamente algoritmos y conjuntos de parámetros, hasta que se obtienen resultados de la calidad deseada. Para conseguir flexibilidad y conveniencia, los autores proponen un esquema basado en el conocimiento. Donde se automatiza parcial o totalmente el razonamiento utilizado por el especialista en visión artificial, para obtener resultados satisfactorios del sistema. El sistema integrado con los algoritmos de visión artificial se muestra en la figura 2.4 y tiene la peculiaridad de poder habilitarse para un usuario final.



**Figura 2.4:** Arquitectura de un sistema de visión artificial autoajustable. El sistema posee varias etapas de procesado, en las cuales se pueden elegir diferentes algoritmos. Cada algoritmo puede tener uno o más parámetros ajustables. El usuario evalúa los resultados de procesado y el módulo de control usa esta realimentación para cambiar algoritmos o parámetros con el objetivo de mejorar los resultados [Shekhar et al., 1999]

Este tipo de sistema es capaz de autoajustarse, por ejemplo, adaptándose a cambios en las características de los datos y requisitos de funcionamiento, con intervención mínima del usuario. La interacción con el usuario se limita a la evaluación de resultados y no a la selección de algoritmos y parámetros. En el caso de un conjunto grande de imágenes, donde se van a realizar las mismas tareas de procesado de imagen; el sistema se puede ajustar utilizando un conjunto representativo de imágenes y una vez conseguido un funcionamiento satisfactorio, se aplican los algoritmos y parámetros constantemente para el resto de imágenes del conjunto.

Por último, la tabla 2.1 muestra una recopilación de algunas arquitecturas dinámicas y reconfigurables para visión artificial en el nivel del conocimiento y de la aplicación.

AUTORES	TIPO DE ARQUITECTURA	DESCRIPCIÓN
[Guinea et al., 1995]	Arquitectura distribuida para percepción activa	Arquitectura desarrollada para integración de información procedente de sensores en un robot móvil. Se intentan superar las restricciones de tiempo real en entornos dinámicos
[Shekhar et al., 1999], [Shekhar et al., 1997], [Shekhar et al., 1996]	Arquitectura y sistema autoajustable, basados en el conocimiento	Arquitectura para un sistema de visión autoajustable, diseño de sistemas autoajustables e integración basada en el conocimiento de algoritmos para interpretación de imágenes
[Chella et al., 1997]	Arquitectura cognitiva para visión artificial	La arquitectura es cognitiva en el sentido de que varias hipótesis cognitivas se asumen como directrices para su diseño
[Chella et al., 2000]	Arquitectura para interpretación de escenas dinámicas	La arquitectura integra de forma sencilla técnicas de visión artificial y representación de conocimiento simbólico
[Rao & Ballard, 1995]	Arquitectura de visión activa	Arquitectura de visión activa de propósito general basada en representaciones icónicas
[Fayman et al., 1998]	Arquitectura para sistemas de visión activa en tiempo-real	El sistema se diseña modularmente para añadir hardware y software redundante de forma flexible; y también posibilitar reconfiguración del sistema cuando y donde sea necesario
[Maurer & Dickmanns, 1997]	Arquitectura para orientación de un vehículo de forma visual y autónoma	Arquitectura jerárquica para orientación de un vehículo de forma visual y autónoma. Consta de cuatro niveles: nivel vehículo, nivel 4D, nivel basado en reglas y nivel basado en el conocimiento
[Benitez, 2003]	Arquitecturas reconfigurables	Rendimiento de arquitecturas reconfigurables para aplicaciones de procesamiento de imágenes
[Solina & Leonardis, 1998]	Arquitectura para modelado selectivo de imágenes	Arquitectura para modelado selectivo de imágenes; que selecciona modelos en función de la tarea, la naturaleza de la escena y las restricciones de computación

AUTORES	TIPO DE ARQUITECTURA	DESCRIPCIÓN
[Tyugu, 2006]	Arquitectura basada en el conocimiento	Arquitectura de sistemas software basados en el conocimiento. La arquitectura de conocimiento es independiente de su implementación
[Lurette & Lecoeuche, 2003]	Arquitectura autoadaptativa	Arquitectura basada en redes neuronales no supervisadas y autoadaptativas para visualización en tiempo-real
[Sutton, 1990]	Arquitectura integrada para aprendizaje, planificación y actuación basada en programación dinámica aproximada	Dos arquitecturas dinámicas “Dyna-PI” y “Dyna-Q”. La primera basada en programación dinámica y la segunda más fácil de usar, implementar y adaptar en entornos variables
[Azar & Weston, 1988]	Arquitectura de visión para fabricación integrada por computador	Visión industrial por computador, se introduce el concepto de representación de información visual en un modelo multicapa

Tabla 2.1: Recopilación de algunas arquitecturas dinámicas y reconfigurables para visión artificial en el nivel del conocimiento y de la aplicación

## 2.2. Inspección visual automática

Este apartado presenta varios conceptos para el desarrollo de un proyecto de inspección visual automática a partir de los trabajos de [Batchelor & Whelan, 1997], [Batchelor, 1998] y su interrelación con la arquitectura cognitiva ARDIS que se verá en el capítulo 5.

La inspección visual automática (IVA o más conocido en inglés “Automated Visual Inspection (AVI)”) es la automatización del control de calidad en el proceso de fabricación de productos en una línea de producción. Normalmente esta tarea de control de calidad se lleva a cabo mediante una cámara conectada a un ordenador y permite inspeccionar grandes superficies a elevada velocidad. La visión industrial por computador incluye la inspección visual automática, además de la integración

de técnicas de iluminación, cámaras, interfaces, etc. como se comentó en el capítulo anterior. Por otro lado, [Mery, 2002] define la inspección visual automática como un proceso de control de calidad que mediante técnicas de procesamiento digital de imágenes y reconocimiento de patrones, determina automáticamente si un producto se desvía de las especificaciones de fabricación.

Brevemente haciendo una analogía con el párrafo anterior y motivando los resultados posteriores, la arquitectura cognitiva ARDIS como se comentará en la próxima parte II resuelve el problema de inspección de defectos superficiales en diferentes tipos de materiales laminados. Se trata de una arquitectura acotada a inspección de superficies capaz de configurar un sistema para inspección visual automática. El sistema está acotado a inspección visual de una superficie laminada concreta (acero inoxidable, papel, plástico, etc.) en una línea de producción. Por otro lado también en la parte II, se explica el entorno-aplicación SIVA II para visión industrial por computador que integra la arquitectura ARDIS, los elementos físicos de captura de imagen (cámara, tarjeta de adquisición, etc.), los elementos de iluminación láser, la interfaz de configuración del sistema de inspección (manual y automático), la interfaz de resultados de control de calidad y la interfaz para la introducción de conocimiento del dominio de inspección de superficies.

Continuando con los sistemas IVA es útil señalar varios consejos prácticos dados por [Batchelor & Whelan, 1997] para el diseño de un sistema de inspección visual automática y las aportaciones de esta tesis que completan las ideas iniciales de Batchelor:

- Concepto de sistema: los sistemas de inspección visual automática se deben desarrollar en los casos de inspección que resulten útiles y siempre después de un estudio de viabilidad del sistema en la aplicación concreta. Si existe una solución alternativa al problema de inspección más barata o fácil es preferible aplicar esta solución a desarrollar un sistema de inspección automático. Por otro lado, los inspectores de línea de producción y los sistemas de inspección

visual no son capaces de conseguir constantemente el 100 % de precisión en una inspección. Por lo tanto, para lograr un control de calidad eficiente, la mejor solución es la sinergia entre los inspectores de línea y los sistemas de inspección visual automáticos.

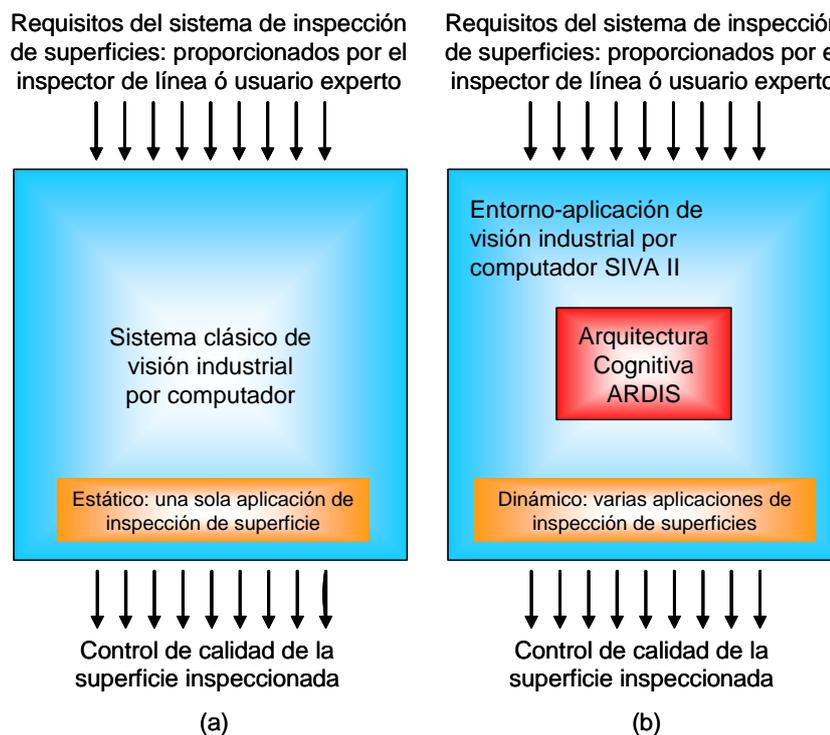
En el caso concreto de inspección de acero inoxidable, en la empresa Acerinox S.A. [Acerinox, 2007] se usan los sistemas de inspección junto con la experiencia de los inspectores de línea en el proceso de control de calidad de acero inoxidable. En la actualidad los sistemas de visión industrial por computador inspeccionan la superficie de acero inoxidable en busca de pequeños defectos de cascarilla residual y muestran los resultados al inspector de línea. El cual toma una decisión de control de calidad en función de estos resultados y su experiencia.

Brevemente y apuntando hacia el objetivo de la tesis, la arquitectura ARDIS embebida en el entorno-aplicación de inspección SIVA II permitirá al inspector de línea no sólo aplicar su conocimiento en el momento de tomar una decisión de control de calidad, sino también en la configuración del sistema de inspección (mediante los requisitos del sistema de inspección como se verá en el capítulo 5). Esta nueva estructura introducida en este trabajo permitirá obtener mejores resultados de inspección debido a la sinergia entre un sistema de inspección visual automático configurado por el inspector de línea para una aplicación concreta y las decisiones de control de calidad adoptadas por el propio inspector de línea o experto de inspección.

- Requisitos: según Batchelor es importante empezar un sistema de inspección visual automática con una clara especificación del sistema, detallando los requisitos del cliente. Esto es cierto, pero normalmente esto solamente se realiza una vez al principio y redundante en baja flexibilidad frente a variaciones no contempladas en el caso inicial. Por ejemplo, si se desarrolla un sistema de inspección para inspección de defectos de cascarilla residual en el caso de ins-

pección de acero inoxidable y varía algún requisito inicial, el sistema quedará inutilizado.

En nuestro caso, también nos basamos en los requisitos, pero permitimos que sean configurables por el inspector de línea o usuario experto, con el objetivo de flexibilizar desde el inicio la configuración del sistema de inspección específico. De esta forma, se busca una solución al problema de variabilidad del entorno o de la aplicación de inspección con la arquitectura dinámica ARDIS. La adaptación a cambios de la superficie a inspeccionar se consigue mediante el entorno-aplicación de inspección SIVA II. Así pues, el entorno-aplicación junto con la arquitectura permiten la flexibilidad necesaria para su utilización en diferentes aplicaciones de inspección de superficies. La figura 2.5 resume la estrategia clásica de inspección y la planteada en este trabajo.



**Figura 2.5:** (a) Estrategia clásica, (b) Estrategia planteada en esta tesis; para abordar el problema de inspección superficial en la industria

- **Diseño:** un sistema de inspección se debe diseñar lo más simple posible. Este principio se denomina “La navaja de Occam”. La navaja de Occam (también llamado principio de economía o de parsimonia) hace referencia a un tipo de razonamiento basado en una premisa muy simple: en igualdad de condiciones la solución más sencilla es probablemente la correcta. El postulado es “Entia non sunt multiplicanda praeter necessitatem”, o “No ha de presumirse la existencia de más cosas que las absolutamente necesarias”. Basándonos en este principio, si se desarrollan dos sistemas distintos con los mismos resultados de inspección, se debe de elegir el que sea más fácil de implementar. La justificación de Batchelor es que un sistema simple tiene menos componentes que pueden fallar. Otro principio importante que también tenemos en cuenta es el denominado principio KISS (“Keep It Simple, Smart”). Este término es un acrónimo que corresponde a la frase en inglés “Mantenlo simple y funcionará”, aunque el acrónimo también corresponde a otras expresiones como “Manténgalo breve y simple” (“Keep It Short and Simple”). El principio KISS recomienda desarrollar un sistema empleando partes sencillas, comprensibles y con errores de fácil detección y corrección. Rechazando lo enrevesado e innecesario en el desarrollo de sistemas complejos.
- **Implementación:** la mayor parte del coste de desarrollo de un sistema se emplea en la integración del sistema en el entorno industrial y el resto se destina al desarrollo de algoritmos de procesamiento de imagen (un único algoritmo para la tarea que deba realizar el sistema). El uso de sistemas más simples puede reducir los costes de integración y destinar mayor presupuesto a los sistemas automáticos de inspección que contemplen variaciones en el entorno, defectos, etc.

Debido a estas necesidades industriales en este trabajo se apuesta por un sistema físico sencillo, eficiente y fácil de integrar para dejar un amplio margen a la investigación del sistema de inspección visual automático, que es reconfi-

gurable en función del entorno, las necesidades de tiempo-real, los requisitos de calidad, etc. específicos de cada tarea de inspección de superficies.

- **Visualización:** los resultados se muestran al operador a través de un VDU (“Video Display Unit”), que es simplemente un monitor que muestra por pantalla los resultados de inspección. En este caso al visualizar los resultados los operadores e inspectores de línea se sienten más seguros con el sistema de inspección.

En los sistemas actuales de inspección sólo se informa al operador pero carecen de mecanismos de realimentación para corregir posibles cambios en la evolución de la inspección de la superficie

### **2.2.1. Requisitos generales de un sistema de inspección visual automático**

Los requisitos generales que debe cumplir un sistema de inspección visual automático se basan en la respuesta y resultados que se esperan del sistema. Estos son importantes debido a que marcan la estructura global del sistema de inspección de superficies. Esta idea se detallará en el capítulo de la arquitectura ARDIS.

Según Pham [Pham & Alcock, 2003] hay 8 requisitos generales de un sistema de inspección visual automático. A continuación se muestran estos requisitos junto con pequeñas aclaraciones que los complementan y justifican:

- **Preciso:** el sistema debe mejorar las capacidades del operario de inspección. Normalmente, el rendimiento humano decae debido a factores como cansancio, despiste, estrés, etc.
- **Rápido:** el sistema debe ser capaz de trabajar en tiempo-real de la aplicación, debido a que en una línea de producción los defectos superficiales pueden aparecer rápidamente en cualquier parte del material. Se particulariza en tiempo-

real de la aplicación debido a que cada aplicación requiere un tiempo específico para llevar a cabo la tarea de inspección. También, este tiempo específico se puede homogeneizar haciendo uso de un buffer. Así, por ejemplo, en el caso de detectar defectos superficiales de  $100 \mu m$  en una plancha de acero inoxidable que avanza a una velocidad de  $1 \frac{m}{s}$ , se necesita un buffer mayor que para detectar defectos de  $10 mm$  en una tabla de madera que avanza a  $10 \frac{cm}{s}$ . El tiempo-real para cada una de estas aplicaciones es distinto, y por tanto, los algoritmos de procesado de imagen y los sistemas hardware y software también.

- Robusto: el sistema no debe verse afectado por el entorno industrial donde se instale. Factores como variaciones en la iluminación, vibraciones o polvo se tienen que tener en consideración en el diseño del sistema de inspección.
- Completo: el sistema debe ser capaz de identificar y localizar los defectos. La calidad de una superficie no sólo depende del número y tamaño de los defectos, también se ve afectada por el tipo de defecto y de su localización. Por otro lado, es necesario mostrar estadísticas de funcionamiento del sistema para analizar su rendimiento.
- Flexible: Idealmente, el sistema debe tener algún modulo configurable por el usuario experto o inspector de línea, para poder transferirlo fácilmente de la inspección de un producto a otro o moverlo a otra línea de inspección. El acceso a partes configurables del sistema por el usuario experto deben ser exhaustivamente controladas y visualizadas.

Brevemente comentar que la flexibilidad es un requisito fundamental de la arquitectura ARDIS y se explicará en el capítulo 5. Esto permite configurar un sistema de inspección para cada inspección de superficie, es decir, un sistema acotado a la inspección de defectos superficiales específicos en un material laminado.

- **Fiable:** si se produce un fallo en el sistema de inspección es necesario hacer automáticamente una copia de seguridad del sistema y activar la alarma correspondiente para avisar al operador.
- **Fácil de mantener:** el sistema de inspección debe ser integrado de forma que todas sus partes sean fácilmente accesibles. Por el lado software, los algoritmos de visión artificial deben escribirse de forma que sean legibles y fáciles de entender. El código debe contener un gran número de comentarios y estar estructurado lógicamente.
- **Redituable:** el coste de desarrollo y puesta en marcha del sistema debe ser compensado por sus beneficios económicos. A menudo, el mayor coste en el desarrollo de un sistema de inspección no está en el hardware, sino en los desarrolladores de software dedicado a una aplicación específica e integración del sistema en el entorno industrial.

### **2.3. Arquitecturas cognitivas en tiempo-real**

El termino cognitivo significa relativo al conocimiento. Según [Albus & Barbera, 2005] una arquitectura cognitiva se define como la estructura organizativa de procesos funcionales y representaciones de conocimiento que permiten el modelado del fenómeno cognitivo. Por otro lado, [Laird et al., 1987] comenta que el objetivo final de una arquitectura cognitiva es proporcionar el fundamento para un sistema capaz de comportamiento inteligente. En general, se proporciona la estructura esencial que permite a un sistema basado en el conocimiento llevar a cabo las tareas cognitivas, utilizando los PSMs (Métodos de Solución de Problemas (en inglés, Problem Solving Methods)) y representaciones apropiadas para las tareas.

La forma de adquirir, representar y utilizar ese conocimiento es mediante las arquitecturas cognitivas o basadas en el conocimiento [Rosenbloom et al., 1991],

[Anderson et al., 1997]. Por lo tanto se puede decir que un sistema está basado en el conocimiento si éste conoce algo de la aplicación para la cual ha sido diseñado. Así, en el caso de inspección de superficies el sistema debe conocer las técnicas apropiadas de detección de defectos superficiales, debe conocer el entorno, las necesidades de tiempo-real, etc. Por ejemplo, los robots autónomos son sistemas cognitivos porque pueden navegar, caminar, escalar, etc. [Gershenson, 2004], [García-Alegre et al., 2007], [García-Pérez, 2004]. De esta forma los sistemas de inspección de superficies también deben ser sistemas cognitivos, y por tanto, conocer las técnicas de inspección, saber inspeccionar diferentes defectos en condiciones variables, interpretar las especificaciones de requisitos de una aplicación específica de inspección de superficies, etc.

El problema de tiempo-real orientado hacia un sistema basado en el conocimiento es responder apropiadamente en un amplio rango de condiciones. Un aspecto de tiempo-real que raras veces se ha tenido en cuenta en arquitecturas cognitivas es la restricción impuesta por el tiempo de respuesta desde que se dispone de información hasta la apropiada respuesta [Coward, 2001]. El problema de tiempo-real en arquitecturas cognitivas es una tarea compleja que ha sido abordada por varios autores en diferentes materias, por ejemplo, en robótica móvil [Benjamin et al., 2006], [Bellas et al., 2006], control adaptativo y visualización [Han et al., 2001], reconocimiento visual [Kuniyoshi & Inoue, 1993], visión por computador [McCormick et al., 1982], etc.

En concreto, la arquitectura ARDIS que se presenta en este trabajo está modelada con “Poseidon for UML” [Poseidon, 2006] que es una herramienta de modelado UML (Unified Modeling Language) [Eriksson & Penker, 1998] sobre Java. El modelado nos permitirá visualizar y especificar la estructura de la arquitectura ARDIS. Los principios de modelado son cuatro, según [Booch et al., 2005]. Primero, la elección del modelo influye directamente en la forma de abordar el problema y su solución. Segundo, cada modelo se puede expresar en diferentes niveles de precisión. Tercero, los mejores modelos están conectados a la realidad. Y, finalmente,

los sistemas complejos se abordan más fácilmente mediante un conjunto pequeño de modelos casi independientes con múltiples puntos de vista. Un modelo nos permite entender un sistema, pero ningún modelo es suficiente. En cualquier sistema hacen falta varios modelos que están conectados unos a otros para entender una tarea.

UML es una familia de notaciones gráficas que ayudan en la descripción y diseño de sistemas software [Fowler, 2004]. En concreto, sistemas software desarrollados desde el punto de vista de la programación orientada a objetos. Así, UML es un lenguaje para visualización, especificación, construcción y documentación de los elementos de un sistema intensivo software. Por otro lado, UML es útil para modelar sistemas complejos y particularmente apropiado para sistemas en tiempo-real [Douglass, 1998], [Lavagno et al., 2003].

Por otro lado, la arquitectura ARDIS se desarrolla siguiendo la metodología CommonKADS y utiliza UML para mostrar los diagramas de actividad, de estados, de clases y de Casos de Uso. En [Schreiber et al., 2000] se describe para cada diagrama los elementos básicos, su notación y para que propósitos se puede usar el diagrama en CommonKADS.

Las tareas complejas reales como la tarea de inspección de superficies, tienen asociada la complejidad de funcionamiento en tiempo-real [Kushleyeva et al., 2005]. En el caso de la arquitectura ARDIS se tiene en cuenta el tiempo-real de dos formas. La primera relativa al tiempo de reconfiguración del sistema de inspección de una superficie. Es decir, si se produce una variación en el entorno o el defecto a inspeccionar cambia, el tiempo de reconfiguración de un nuevo sistema está definido en función de la aplicación. La segunda se refiere al tiempo en ejecutarse el algoritmo o secuencia de técnicas de visión por computador para inspección de la superficie, y éste viene marcado por el tipo de superficie, por el tipo de defecto, por la velocidad de avance del material laminado, etc.

Resumiendo, estos dos primeros capítulos se han centrado en el estado del arte relativo a los sistemas de inspección visual por computador en la industria y sus ne-

cesidades, lo que ha conducido a comentar brevemente las soluciones que se plantean a estas necesidades a lo largo de la tesis.

El siguiente capítulo muestra la aplicación real de inspección de defectos superficiales de oxido en acero inoxidable, que a partir de estos experimentos nos ha permitido adquirir el conocimiento genérico de inspección de superficies que posteriormente usará la arquitectura ARDIS y han planteado diferentes necesidades que se han abordado en la parte II de la tesis.



## Capítulo 3

# Detección de defectos superficiales de oxido en acero inoxidable en tiempo-real

La detección de defectos superficiales es una tarea compleja que requiere conocimiento del dominio de inspección de superficies. Este conocimiento se puede adquirir de diversas fuentes bibliográficas, pero normalmente es incompleto, específico de una aplicación concreta y poco preciso. Por esta razón, en este capítulo se presenta parte del conocimiento experimental de inspección de superficies adquirido en la realización de esta tesis doctoral – mediante la inspección de cascarilla residual en laminados de acero inoxidable – que nos ayudará a generalizar para la inspección de otros materiales laminados como pueden ser madera, plástico, papel, etc. De esta forma, por ejemplo, el conocimiento de tiempo-real adquirido para detección de cascarilla residual se puede aplicar, según el caso, a otros materiales laminados.

El capítulo comienza con una breve descripción de cascarilla residual y continúa con un estudio espectrofotométrico que muestra el rango de frecuencias óptimo para discriminar entre acero inoxidable y cascarilla residual. La segunda parte está compuesta por tres métodos de detección de cascarilla residual que gracias a ellos

hemos podido adquirir el conocimiento de inspección de superficies necesario, que posteriormente lo utilizará la arquitectura dinámica ARDIS. Los tres métodos son detección de cascarilla residual con cámara CCD, sensor fotoeléctrico y espectroscopia óptica de emisión espacio-temporal. El primer y segundo método de detección de cascarilla residual se ha realizado en colaboración entre la Universidad de Málaga (Departamento de Electrónica), el Instituto de Microelectrónica de Sevilla (C.S.I.C.) y el Instituto de Automática Industrial (C.S.I.C.); en el marco del proyecto “Proyecto de Investigación sobre la Metodología de Detección de Cascarilla Residual en líneas de proceso de material procedente de laminación en caliente” para la empresa ACERINOX S.A. (fabricante de productos planos y largos de acero inoxidable (bobinas, láminas, chapas, barras, etc.)). El tercer método se ha llevado a cabo entre el Instituto de Óptica (C.S.I.C.) y el Instituto de Automática Industrial (C.S.I.C.).

Como ya se ha comentado, el conocimiento experimental – adquirido con estos experimentos – de inspección de superficies lo utilizará la arquitectura dinámica ARDIS.

### **3.1. Conceptos sobre acero inoxidable y óxido de hierro (cascarilla residual)**

El acero inoxidable es una aleación compuesta principalmente de hierro, con un contenido mínimo de cromo de un 10,5%. Dicho elemento crea una capa superficial invisible que resiste la oxidación y hace al material resistente a la corrosión a temperatura ambiente. Sin embargo, cuando el acero inoxidable se calienta a elevadas temperaturas, tal como ocurre en la etapa de templado durante el proceso de producción, se forma una capa superficial de óxido de hierro, a no ser que el material esté completamente rodeado por una atmósfera protectora. Para restaurar las condiciones óptimas de resistencia a la corrosión del acero inoxidable es necesario eliminar dicha capa. Los métodos de limpieza de óxido habituales se basan en la

aplicación de ácidos, chorros de arena o granalla metálica, cepillos mecánicos, etc. Ahora bien, dado que dichos óxidos pueden variar en naturaleza y composición, no existe un único proceso que elimine todos ellos. Así, al no producirse una limpieza completa del material aparecen restos de óxido, denominados cascarilla residual, en el acero inoxidable y cuya limpieza es esencial para conseguir la máxima resistencia del material contra la corrosión, especialmente en los procesos posteriores de laminación en frío donde manchas diminutas en la plancha gruesa pueden convertirse en grandes manchas superficiales en la plancha laminada (es decir, pequeñas zonas de cascarilla residual entorno a 50 - 100  $\mu m$  procedentes de la fase de laminación en caliente, se convierten en regiones apreciables a simple vista, al estirar el material en la fase de laminado en frío).

La identificación de la presencia de óxido de hierro sobre la lámina de acero inoxidable previamente a su laminación en frío resulta pues esencial para optimizar el proceso de producción y mejorar la calidad del material obtenido.

### **3.2. Descripción de cascarilla residual en el nivel del conocimiento (lenguaje natural)**

A continuación se hace una breve descripción de la cascarilla residual que se aloja en el grano del acero inoxidable, y posteriormente este conocimiento se utilizará en la arquitectura ARDIS:

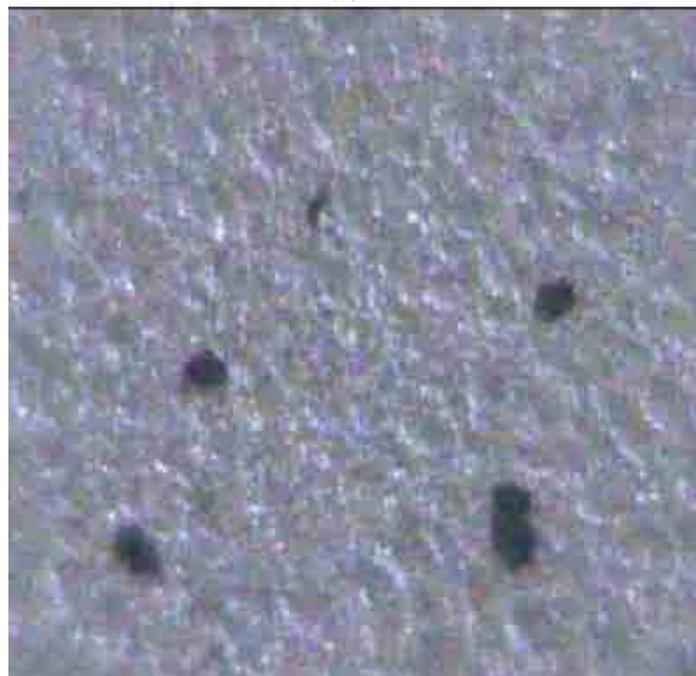
- La cascarilla tiene un rango de niveles de gris característico, próximo al menor nivel de gris de la imagen. Este rango es debido a que la cascarilla se aloja en el grano natural del acero inoxidable. La cascarilla que se aloja en el fondo del grano tiene un valor de reflectancia menor que la alojada en los bordes del grano.
- El menor nivel de gris de la imagen puede conducir a error si se asocia al

nivel de gris de cascarilla, debido a que la cámara introduce ciertos niveles de gris mínimos (ruido de captura de imagen introducido por la óptica, sensor, iluminación, etc). Estos fenómenos de ruido se observan en los extremos de la imagen.

- Por otro lado, la superficie del acero inoxidable es irregular y debido a que la cascarilla residual se aloja en los granos naturales del acero inoxidable, pueden existir diferentes defectos de cascarilla residual en forma y área. Así pues, es difícil establecer un rango exacto de formas o áreas.
- Las planchas de acero inoxidable se pueden clasificar, en relación al acabado superficial de la plancha de acero inoxidable, en mate o brillante. Es decir, acabado superficial de grano fino o acabado superficial de grano gordo. Estos dos tipos de acabado superficial influyen directamente en la iluminación a utilizar en la inspección de acero inoxidable. Las dos clases de grano del acero inoxidable se muestran en las siguientes dos imágenes capturadas con lupa electrónica, donde se aprecia la diferencia de grano. La figura 3.1 (a) muestra una plancha de acero inoxidable tipo B (poca cascarilla) con acabado brillante y la figura 3.1 (b) una plancha de acero inoxidable tipo D (mucho cascarilla) con acabado mate.
- La cascarilla suele depositarse en el acero inoxidable en forma de disco.
- El tamaño empírico de la cascarilla se suele establecer en un rango característico. El límite inferior son 20 micras y el superior va desde las 100 a las 1000 micras.
- La cascarilla se encuentra agrupada por zonas (bandas o regiones). Normalmente, no se encuentran manchas de cascarilla individuales. La cascarilla aparece debido a un fallo en los sistemas de limpieza de cascarilla en un proceso de producción anterior. Por lo tanto, es normal que aparezca en franjas o regiones en la dirección de avance de la plancha de acero inoxidable.



(a)



(b)

**Figura 3.1:** (a) Plancha de acero tipo B. Acabado superficial brillante. Grano gordo, (b) Plancha de acero tipo D. Acabado superficial mate. Grano fino

### **3.3. Estudio espectro-fotométrico de óxido de hierro frente a acero inoxidable base**

El primer paso antes de diseñar un sistema de inspección de superficies, es adquirir todo el conocimiento posible de la superficie a inspeccionar y los defectos que pueden aparecer en el material. Normalmente, el conocimiento se puede adquirir de diversas fuentes bibliográficas, pero también resulta útil hacer pruebas específicas del material a inspeccionar. En el caso de inspección de acero inoxidable para detección de microdefectos de cascarilla residual se realizan varias pruebas de reflectancia por separado, primero a una muestra de acero inoxidable sin defectos y segundo a cascarilla residual (óxido de hierro), para conocer el rango de frecuencias donde mejor se distingue entre acero inoxidable y cascarilla residual, y por tanto, usar el sensor apropiado (visión infrarroja, visible, etc.) para esta tarea de inspección de superficie [Martín et al., 2003a].

#### **3.3.1. Curvas espectrales de seis muestras de acero inoxidable frente a óxido**

En este apartado se muestra la reflectancia en el acero inoxidable (gráfica azul) y el óxido (cascarilla residual, gráfica roja) por separado. Es decir, se tomó una muestra sólo de acero inoxidable y se calculó su reflectancia, igualmente, se realizó con el óxido de hierro. Los resultados obtenidos se comentan a continuación.

Las figuras 3.2 y 3.3, muestran los primeros datos experimentales, donde podemos observar claramente que la reflectancia es mayor en el acero inoxidable (gráfica azul). Además, al aumentar la longitud de onda, aumenta la reflectancia; observándose mayor reflexión en el IR cercano. La reflectancia en el acero inoxidable comienza a aumentar desde la región ultravioleta hasta el IR cercano, quedando claramente definido este crecimiento en la región visible. En el óxido de hierro, ocurre un comportamiento distinto, comienza decreciendo en la región ultravioleta hasta 250 nm;

aproximadamente, se mantiene constante en el intervalo 250 nm - 550 nm, aumenta de 550 nm hasta 1200 nm y se mantiene casi constante en las siguientes longitudes de onda del IR cercano.

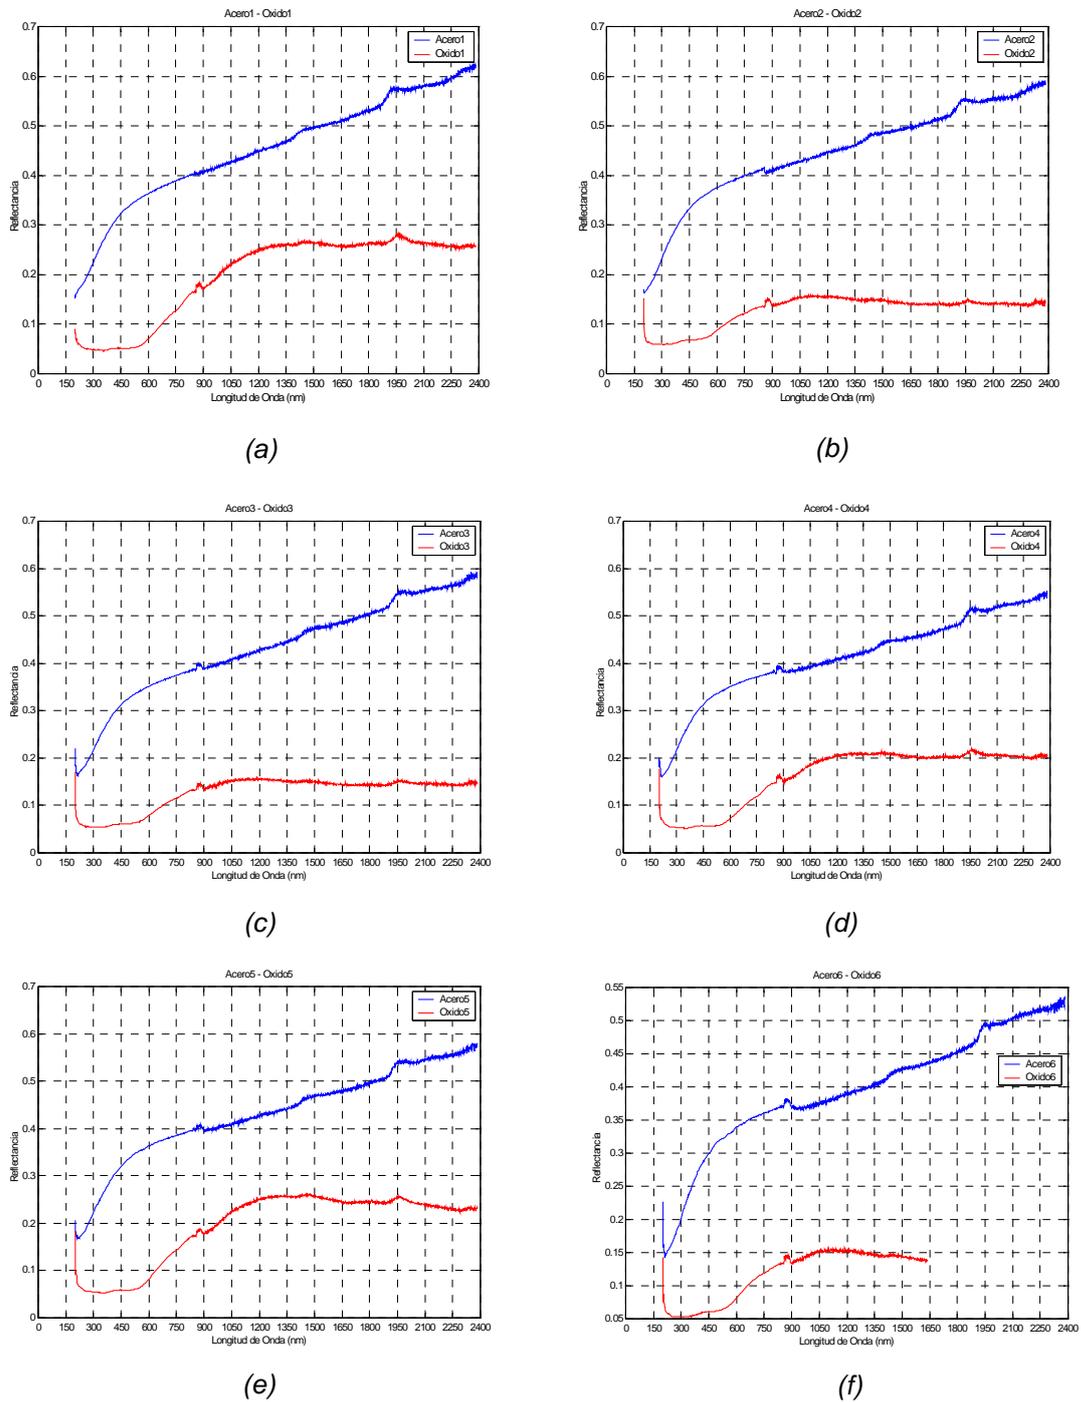
Además, es preciso observar la ausencia de picos correspondientes a los niveles energéticos de banda estrecha propios de los iones ferroso y férrico. Esto elimina la posibilidad de una segmentación óptica de las manchas de óxido de hierro mediante filtros interferenciales de la longitud de onda correspondiente a estos máximos propios del óxido.

### **3.3.2. Estadísticas punto a punto (media y desviación estándar)**

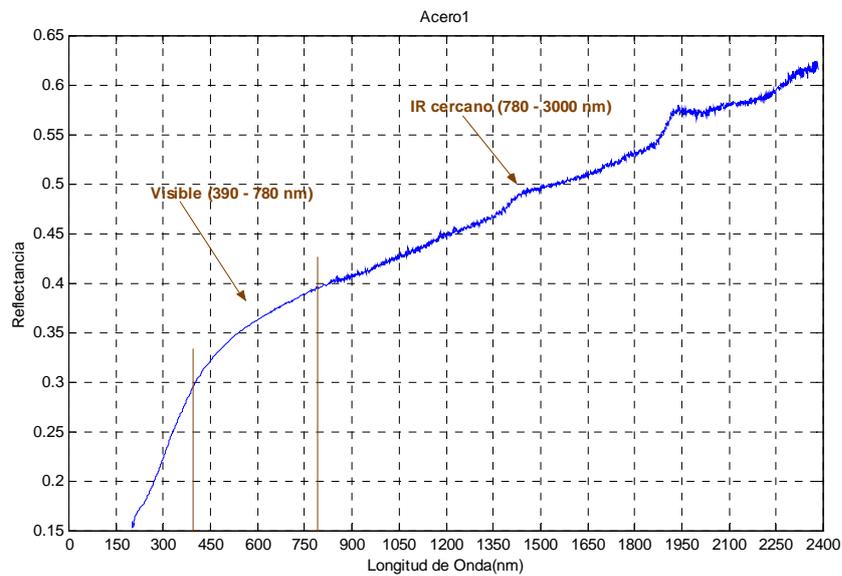
Para analizar las 6 gráficas de la figura 3.2, se calcula la media y la desviación estándar. Así, obtenemos una visión clara de la reflexión en el acero inoxidable y su rápida comparación con la reflexión en el óxido de hierro. La figura 3.4 muestra la media y podemos observar que la reflectancia, en el acero inoxidable y también en el óxido, comienza decreciendo en el ultravioleta siendo esta caída mayor en el óxido de hierro. A partir de esta caída, la reflexión en el óxido se estabiliza a un valor casi constante hasta aproximadamente 550 nm, desde esta longitud de onda crece hasta 1200 nm y se mantiene de nuevo casi constante, por otro lado, la reflectancia en el acero inoxidable después de su pequeña caída comienza a crecer hasta el IR cercano.

Podemos observar, que en el ultravioleta y visible se produce menor dispersión que en el IR cercano y la reflectancia en el óxido es casi constante al final del UV y comienzo del visible, por tanto, es conveniente trabajar en esta parte del espectro electromagnético.

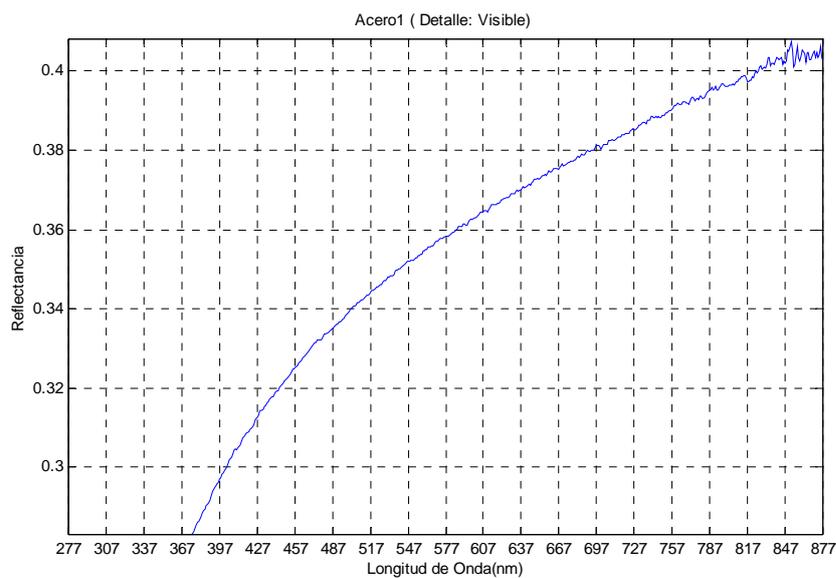
A continuación, se calculó la desviación estándar (figura 3.5). Obteniéndose los mejores resultados en la región final del ultravioleta y en el visible, ya que, como podemos observar en el acero inoxidable el intervalo 250 nm – 750 nm posee la



**Figura 3.2:** Reflectancia frente a longitud de onda. (a)-(f), 6 muestras de acero comparadas con 6 de óxido

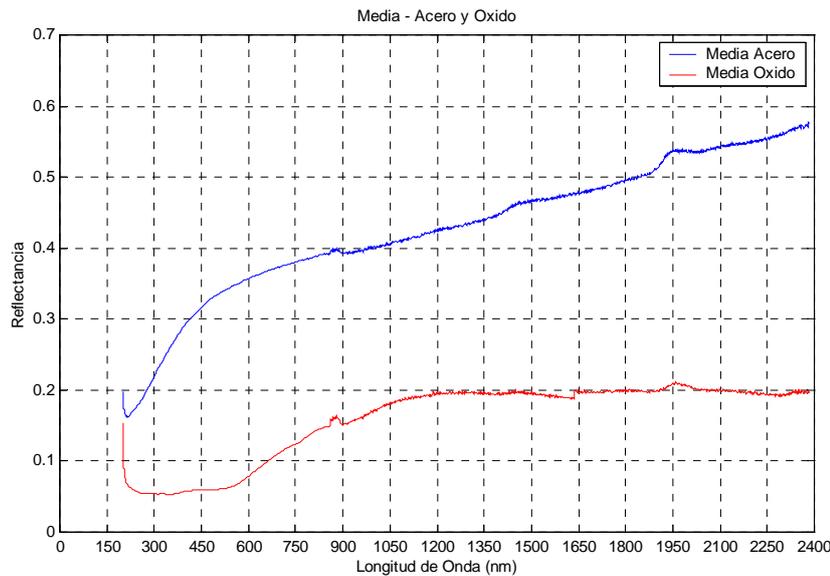


(a)



(b)

**Figura 3.3:** (a) Reflexión en la primera muestra de acero, donde se señala la región del espectro electromagnético correspondiente al visible y al IR cercano. (b) Detalle del visible, donde se observa poca dispersión en comparación con el IR cercano



**Figura 3.4:** Reflectancia media de las 6 muestras

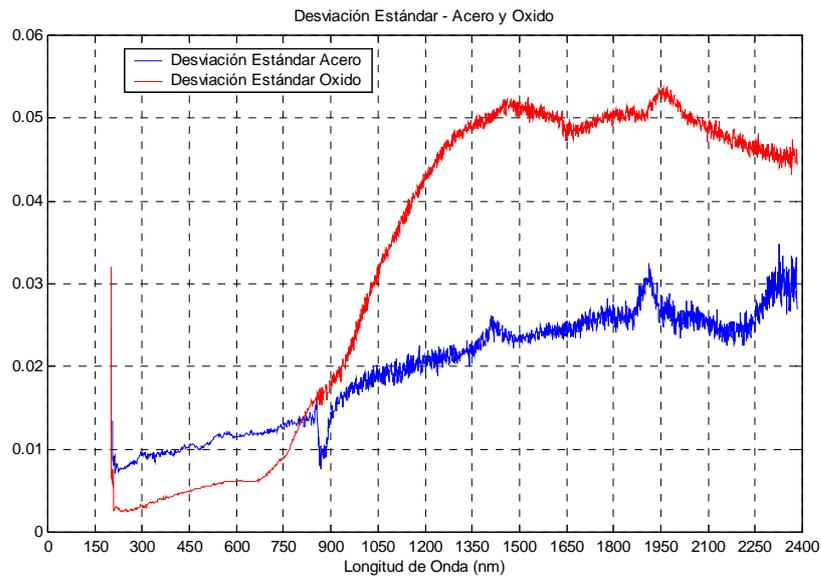
menor desviación estándar y la dispersión es pequeña en comparación con la del IR cercano. En el óxido, se dan unas condiciones parecidas, la menor desviación se da en el intervalo 250 nm – 650 nm y la dispersión es casi inexistente.

Se observa también, en el óxido un gran aumento de la desviación estándar desde 650 nm hasta 1500 nm, manteniéndose casi constante a partir de este último valor; además, existe mayor dispersión en el IR cercano que en final del UV y visible. En el acero inoxidable, la desviación crece progresivamente a partir de 750 nm y se observa una dispersión grande en el IR cercano.

Así, nuevamente, se cree conveniente trabajar en la región del espectro correspondiente al final del UV y visible.

### 3.3.3. Gráfica diferencia de óxido frente a acero inoxidable

Esta última gráfica, finaliza el estudio espectro-fotométrico. Los resultados obtenidos, resuelven si es mejor trabajar en la región final del UV o en el visible. Así, se



**Figura 3.5:** Desviación estándar de las 6 gráficas de acero y óxido

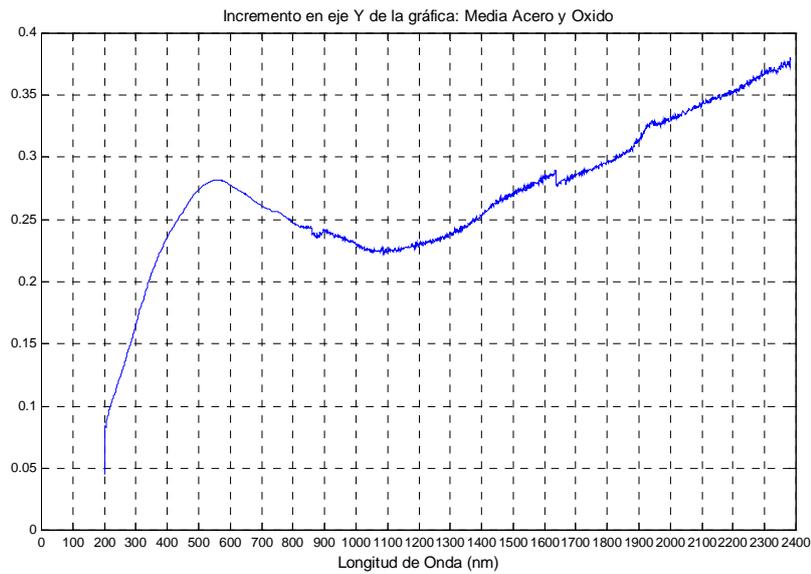
justifica la región del espectro electromagnético óptima para desarrollar un sistema de detección de cascarilla residual.

La figura 3.6 muestra que la máxima diferencia de reflexión entre el acero inoxidable y el óxido para cada longitud de onda, está entorno a los 550nm, donde existe un máximo relativo. Con lo cual, la región visible del espectro y concretamente la perteneciente al verde ofrece las mejores condiciones de discriminación entre acero inoxidable y óxido.

### 3.3.4. Filtro óptimo en paso de energía diferencial frente a total

Una vez realizado el estudio espectro-fotométrico, donde se ha observado experimentalmente la mejor región de trabajo del espectro electromagnético, se ha de elegir un filtro que se ajuste a esta región.

Así, este filtro debe dejar pasar longitudes de onda entorno a 550 nm (filtro



**Figura 3.6:** Diferencia de reflectancia entre acero y óxido para cada longitud de onda. Se observa claramente un máximo relativo, aproximadamente, en 550 nm

verde) y poseer una transmitancia acorde con la reflectancia en acero inoxidable y óxido.

De esta forma, si utilizamos una cámara de vídeo con filtro verde, podremos diferenciar mejor el acero inoxidable del óxido (casquilla residual) en las imágenes.

### 3.4. Sistemas de detección de microdefectos superficiales de casquilla residual en tiempo-real

En este apartado se resumen tres métodos para la detección de defectos de óxido superficial (casquilla residual) en planchas de acero inoxidable. Los experimentos proporcionan parte del conocimiento de inspección de superficies que posteriormente utilizará la arquitectura ARDIS como base de conocimiento. Estos métodos de

detección reúnen las siguientes características generales:

- Discriminan suficientemente la presencia de cascarilla de otro tipo de defectos o características de la superficie.
- Control de calidad en base a la densidad de cascarilla residual encontrada, según los criterios de calidad establecidos en ACERINOX.
- Se pueden instalar en el entorno industrial concreto de la línea de proceso objetivo (línea AP2 de ACERINOX), y esto implica:
  - Robustez adecuada a las características del entorno.
  - Facilidad de mantenimiento (según el caso).
  - Viabilidad económica de instalación y mantenimiento (según el caso).

### **3.4.1. Detección con cámara CCD**

El primer método utiliza técnicas convencionales de adquisición, iluminación y procesamiento de imágenes, para la detección del defecto de cascarilla superficial. En este primer caso se describe un sistema clásico de inspección de superficies.

Los experimentos se realizan en muestras de planchas de acero inoxidable en el laboratorio y sin movimiento, pero atendiendo en lo previsible a las condiciones necesarias para que los resultados puedan extrapolarse al entorno de un prototipo real. En particular, se tienen en cuenta los siguientes aspectos:

- Resolución mínima necesaria: atendiendo al tamaño mínimo de las manchas de cascarilla, determinar qué longitud del plano objeto (plancha de acero inoxidable) debe captar un píxel de la cámara.
- Tiempo de exposición máximo: puesto que realmente las planchas están en movimiento, se hace necesario utilizar tiempos de exposición suficientemente cortos para evitar que las imágenes puedan resultar difuminadas.
- Tipo de iluminación: si ha de ser pulsante o continua, intensidad necesaria, colimada o no, ángulo de incidencia, etc.
- Aspectos ópticos: en este caso se han de cubrir aspectos como distancia física entre la cámara y la plancha de acero inoxidable, distancia focal, profundidad de campo, ángulo de observación, etc.

- Mecanismos de sincronización en caso de iluminación pulsante.
- Velocidad de transferencia de imágenes: se han de determinar las alternativas existentes en cuanto a velocidad de transferencia de imágenes (desde la cámara al sistema de almacenamiento/procesamiento) y su coste, identificando opciones óptimas. Es decir, identificar los cuellos de botella ante la conveniencia de adquirir y procesar el mayor número posible de imágenes por segundo al menor coste.
- Mecanismos de control automático del proceso de adquisición y transferencia.
- Algoritmos de procesamiento de imagen necesarios y evaluación de la capacidad de procesamiento necesaria.
- Estudio de robustez del sistema frente a ondulaciones del material.
- Mantenimiento de la información necesaria para verificar los resultados obtenidos.

En la detección con cámara CCD las imágenes son digitales, es decir, muestreadas en el tiempo en las dos dimensiones espaciales, y en el “nivel de gris” de cada píxel. La utilización de imágenes en color se descarta en la detección de cascarilla residual por la complejidad, el coste adicional que supone y la poca información adicional que proporciona. En este caso, se distingue únicamente un tipo concreto de elemento (mancha de cascarilla) sobre un fondo de una apariencia uniforme (acero inoxidable).

El hardware necesario es el típico de los sistemas de inspección visual por computador: una cámara, un sistema de iluminación y un ordenador con una tarjeta de adquisición de imágenes. También, son necesarios otros componentes como un soporte mecánico para la cámara y la fuente de luz; o elementos electrónicos para el control remoto de la cámara, de sus parámetros de funcionamiento, etc. En cuanto al software, se pueden utilizar librerías que contengan funciones específicas para el procesamiento de imágenes.

Por otro lado, la adquisición de la imagen es un aspecto crítico que afecta a la viabilidad y robustez del sistema de detección, mientras que la velocidad de procesamiento afecta básicamente a la cantidad de área inspeccionada. El problema de adquisición se divide a su vez en dos: la cámara, y el sistema de iluminación.

También, existen otras consideraciones como la posición relativa de uno y otro, la posición con respecto a la bobina y el sistema óptico, que afectarán al resultado final. Los aspectos críticos en el proceso de adquisición son la resolución (en el sentido del tamaño del píxel en el plano objeto, es decir, en la plancha de acero inoxidable), el tiempo de exposición, la profundidad de campo, la intensidad de luz, la no-direccionalidad de la misma, etc.

#### **3.4.1.1. Resolución de la cámara**

Uno de los requisitos de inspección de un defecto de cascarilla residual establecido por ACERINOX S.A. es el tamaño mínimo detectable, comprendido entre 0,02 y 0,1 mm. Pero, en el caso de inspección convencional con cámara CCD se especifica de 0,05 a 0,1 mm. Para un procesado adecuado es conveniente tomar las imágenes con varios píxeles por mancha de cascarilla residual. Por ejemplo, en este caso se especifica que son suficientes 4 píxeles por mancha (2 x 2). Con estos datos se puede calcular cuanto mide un píxel en el plano de la plancha, o equivalentemente, la densidad de píxeles por milímetro (PPM) necesaria para esta aplicación de inspección de superficies:

$$PPM = \frac{NUM}{TAM} \quad (3.1)$$

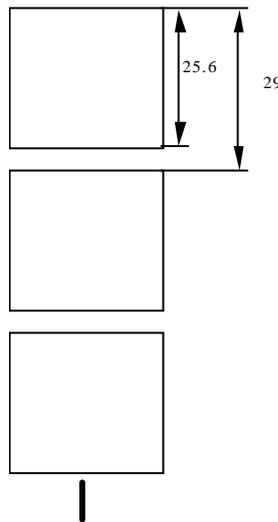
Donde NUM es el número de píxeles por mancha en cada dirección y TAM el tamaño mínimo detectable de mancha. Por tanto, para el intervalo de tamaños especificado en los requisitos de inspección, PPM ha de tener un valor de entre 20 y 40 píxeles/mm. La inversa de PPM es el tamaño del píxel en el plano objeto, que resulta pertenecer al intervalo [0.025, 0.050] mm [Martín et al., 2003c].

Los requisitos del sistema de inspección de cascarilla residual proporcionan la densidad de píxeles deseada y con este dato se calcula el área abarcada con una resolución dada. Por ejemplo, si se asume un tamaño mínimo detectable igual a 0,05 mm, o equivalentemente, un  $PPM = 40$  píxeles/mm y se usa una cámara con sensor

de área de 1024 x 1024 píxeles de resolución, se abarca en cada dirección:

$$l = \frac{\text{resolución}}{PPM} = 25,6\text{mm} \quad (3.2)$$

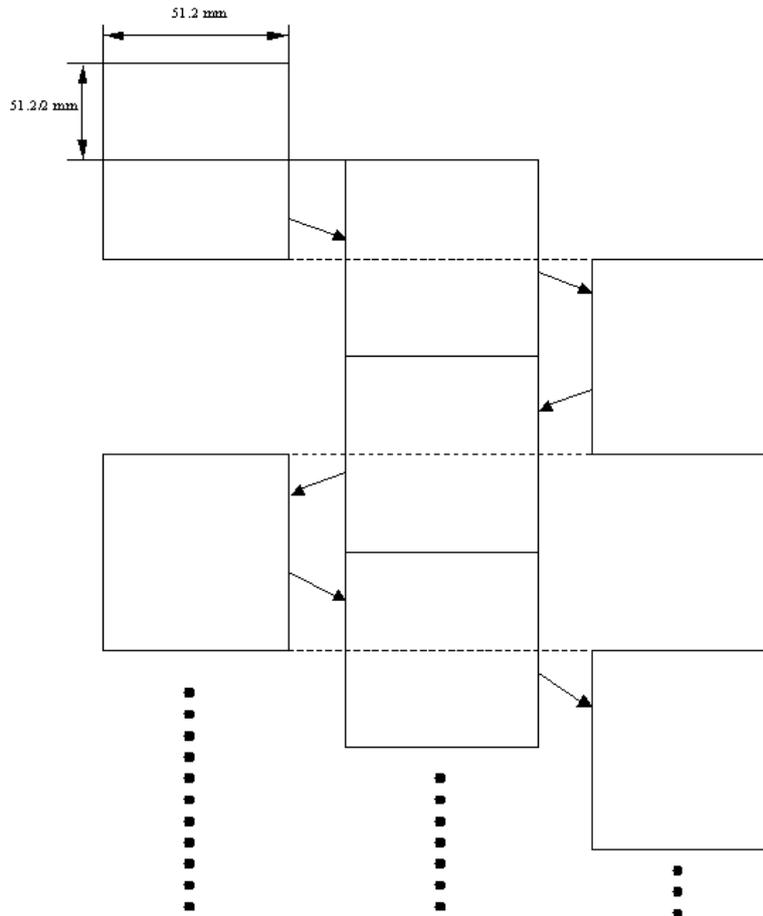
Una cámara con esa resolución puede llegar a captar unos 40 fotogramas por segundo, o lo que es lo mismo, un fotograma cada 25ms; en ese tiempo, sabiendo que la plancha tiene una velocidad aproximada de 70 m/min, ésta avanza 29 mm. Por tanto, se inspecciona un cuadrado de 25.6 mm de lado cada 29 mm (figura 3.7). Luego prácticamente se puede conseguir un cubrimiento completo en la dirección de movimiento de la plancha (dirección longitudinal). Sin embargo, en la dirección transversal al movimiento el cubrimiento es sólo del 1.6% (asumiendo la máxima anchura (1,6 metros)), con lo que serían necesarias 60 cámaras para cubrir el área completa de la plancha.



**Figura 3.7:** Cubrimiento logrado con una cámara de 1024 x 1024 píxeles y a una velocidad de captura de 40 fotogramas/seg

Si se considera 0,1 mm como tamaño mínimo de mancha, la mejora en los resultados es de al menos el doble. En ese caso,  $l = 51,2$  mm y se cubre un 3.2% de la anchura de la plancha, con lo que hacen falta 30 cámaras para completar el cubrimiento en la dirección transversal. También se mejora la dirección longitudinal,

pero existe un solapamiento en la toma de las muestras de alrededor de un 50%. Esto permite pensar en esquemas de muestreo como el que aparece en la figura 3.8. Así se consigue que el área procesada con una sola cámara sea aproximadamente el 7.5 % de la plancha completa.



**Figura 3.8:** Esquema de muestreo en zig-zag con cámara de 1024 x 1024 y 40 fotografías/seg. PPM = 20 píxeles/mm

### 3.4.1.2. Aspectos ópticos

Los aspectos ópticos se seleccionan para cumplir con los requisitos de inspección marcados por Acerinox. Uno de los requisitos es la distancia de seguridad entre el sistema óptico y la plancha de acero inoxidable a inspeccionar. Este requisito

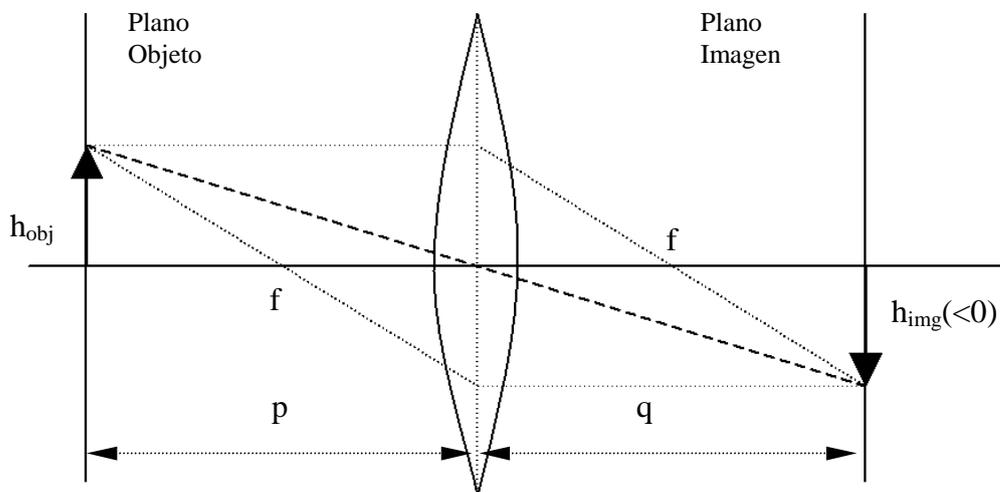
pertenece a las restricciones de entorno, debido a que no puede ser menor de 300 mm. El procedimiento para calcular la distancia focal necesaria y obtener la distancia al objeto (DO) requerida (distancia objetivo-plancha = 30 cm) es el modelo de lente fina, que se muestra a continuación:

$$\frac{1}{p} + \frac{1}{q} = \frac{1}{f} \quad (3.3)$$

$$M = \frac{-h_{img}}{h_{obj}} = \frac{p}{q} \quad (3.4)$$

$$DO = f \left( 1 + \frac{1}{M} \right) \quad (3.5)$$

Donde  $f$  es la distancia focal,  $p$  y  $q$  son las distancias del plano objeto y el plano imagen, respectivamente, a la lente y  $M$  el factor de magnificación. Todas las magnitudes se muestran gráficamente en la figura 3.9.



**Figura 3.9:** Óptica. Modelo de lente fina

Entonces, si en el plano objeto ha de haber 40 píxeles/mm (para un tamaño de mancha de 0,05 mm), en dicho plano un píxel mide 0,025 mm ( $h_{obj} = 0,025mm$ ).

Luego se puede extraer el factor de magnificación siguiendo la ecuación 3.4, utilizando la relación entre el valor anterior y el tamaño físico de un píxel, que será tomado igual a  $10 \mu m$  ( $h_{img} = -10\mu m$ ; valor medio de las cámaras comerciales). Así:

$$M = 0,4$$

Con lo que, introduciendo DO y M en la ecuación 3.5:

$$f = 86mm$$

Si se repiten los cálculos para TAM = 0,1 mm, se obtiene un factor de magnificación de 0,2 y una distancia focal — con DO = 300 mm — de 50 mm.

Para calcular la profundidad de campo, se ha de introducir un nuevo parámetro: la apertura relativa, o número F ( $F/\#$ ); ésta se define como la relación entre la distancia focal y la apertura

$$F/\# = \frac{f}{D_{apertura}} \quad (3.6)$$

Por definición, un  $F/\#$  grande, implica una apertura relativa pequeña. Un sistema de este tipo es llamado lento y el contrario rápido, en relación al tiempo de exposición que puede usarse en ellos. A igualdad de focales un sistema con, por ejemplo  $F/3$ , requerirá más tiempo de exposición que un sistema con  $F/1$  para conseguir el mismo nivel de brillo.

Si se introducen los valores utilizados para calcular los anteriores parámetros y un  $F/\#$  de 16 en la siguiente ecuación 3.7, se obtiene una profundidad de campo de 9,6 mm.

$$DOF = \frac{2 \cdot TAM_{pix} \cdot F/\# \cdot (1 + M)}{M^2} \quad (3.7)$$

$F/16$  es un valor elevado, aunque existen ópticas cuyo  $F/\#$  máximo es 32 e incluso superior. Sin embargo, si se reduce en exceso la apertura, comienzan a aparecer efectos de segundo orden en la toma de las imágenes (difracción, entre otros). Así pues, es habitual usar en la adquisición, al menos, la mitad de la apertura máxima. Es decir, para tomar imágenes con  $F/16$ , se ha de adquirir una óptica de  $F/32$ .

Una profundidad de campo pequeña puede ser problemática, debido a las ondulaciones laterales y a las variaciones en el grosor de la plancha de acero inoxidable. Por lo tanto, es recomendable un sistema óptico con elevada profundidad de campo y su lugar de instalación es un rodillo de la línea de producción para eliminar las ondulaciones.

### 3.4.1.3. Tiempo de exposición

El tiempo de exposición es uno de los requisitos más importantes de un sistema de inspección de superficies. En este apartado, se adquiere el conocimiento relativo a este requisito a partir de los resultados del proyecto de detección y clasificación de cascarilla residual en ACERINOX S.A. y que posteriormente formará parte de la base de conocimiento que utiliza la arquitectura dinámica ARDIS. Este conocimiento permite configurar el tiempo de exposición de cada sistema de inspección de superficie, para inspeccionar apropiadamente una superficie particular.

El tiempo de exposición es el tiempo que el sensor de imagen capta luz. Esto es crítico en sistemas que toman imágenes de objetos en movimiento, puesto que éstas pueden aparecer borrosas. El tiempo de exposición necesario en esta tarea de inspección se relaciona con la velocidad de la plancha y con alguna longitud característica del problema. Inicialmente, para poder anticipar un orden de magnitud en el que se ha de mover dicho tiempo de exposición, se toma como estimación:

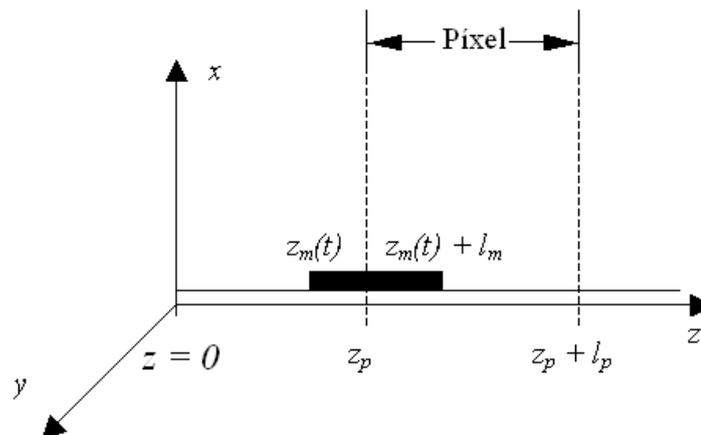
$$T_{exp} = \frac{TAM_{pixel}}{v_{lámina}} = 25\mu s \quad (3.8)$$

siendo de nuevo  $TAM_{pixel}$  el tamaño del píxel en el plano objeto, que se ha tomado igual a 0,025mm, ya que una mancha cuyo tamaño sea el mínimo detectable puede medir 0,050mm y cuenta con dos píxeles en cada dirección. La velocidad de la lámina de acero inoxidable se ha tomado en este caso 1 m/s.

Este tiempo es muy restrictivo en las cámaras actuales. Además, se necesita una potencia luminosa demasiado elevada para tomar imágenes con tiempos tan

pequeños. Estas dos restricciones encarecen mucho el equipo de inspección industrial (cámara y sistema de iluminación). A continuación se estudia si se puede aumentar este tiempo con garantías.

La elección del tiempo de exposición es una cuestión importante en inspección de laminados a alta velocidad. En inspección de acero inoxidable la plancha se mueve a gran velocidad y el objeto a inspeccionar es de reducido tamaño. Estas características pueden llevar a que las manchas se vean difuminadas, o incluso a que no aparezcan en la imagen. A continuación se muestra un estudio teórico acerca de cómo afecta el movimiento de una mancha de cascarilla residual en la toma de la imagen. El objetivo será calcular la cantidad de luz integrada por un píxel en función del tiempo de exposición ( $T_{exp}$ ) para poder seleccionar el óptimo. Haciendo uso de la figura 3.10 se definen los convenios y la notación que se emplea en el desarrollo:



**Figura 3.10:** Notación usada en el estudio teórico del tiempo de exposición

- El desarrollo se plantea en una sola dimensión espacial, la de movimiento de la plancha, con la que se hace coincidir el eje  $z$  del sistema de referencia.
- El extremo izquierdo de la mancha es  $z_m(t)$ , asumiendo que la lámina avanza

a una velocidad constante igual a  $v_{lam}$  en la dirección  $z > 0$ :

$$z_m(t) = z_{m0} + v_{lam}t \quad (3.9)$$

- El extremo derecho es  $z_m(t) + l_m$ , donde  $l_m$  es la longitud de una mancha de cascarilla en la dirección  $z$ .
- En principio  $z_{m0}$  es un parámetro libre. Posteriormente se usa para extender el estudio a más de un píxel.
- El extremo izquierdo de un píxel en el plano objeto es  $z_p$  y el derecho  $z_p + l_p$ .
- Cada punto del eje  $z$  emite luz con una exitancia diferente y constante según sea fondo o mancha en cada instante. Se define la función exitancia para todo  $z$  como:

$$M_s(z, t) = \left\{ \begin{array}{ll} M_{s1} & \text{si } z \in [z(t), z(t) + l_m] \\ M_{s2} & \text{e.o.c} \end{array} \right\} \frac{W}{cm^2} \quad (3.10)$$

- Un requisito del sistema de inspección utilizado es que la mancha ocupe al menos dos píxeles en la imagen (caso  $l_m > l_p$ ), pero, también se tiene en cuenta el caso  $l_p > l_m$ , donde la longitud del píxel en el plano objeto es mayor que la longitud de la mancha.
- El planteamiento supone un caso ficticio en el que los rayos de luz salen de la plancha (tanto si es mancha como fondo) perpendiculares a ésta. Para ser rigurosos, habría que tener en cuenta el ángulo sólido de la plancha al píxel, e integrar la radiancia, no la exitancia. Pero eso añade complejidad matemática al estudio y no afecta a las conclusiones cualitativas que se pretenden extraer.

Una vez definido el problema, se enuncia que el valor del píxel una vez pasado un tiempo de exposición es:

$$V_{pixel} = \int_0^{T_{exp}} \int_{z_p}^{z_p+l_p} \int_0^{l_p} M_s(z, t) dy dz dt \quad (3.11)$$

Para reducir el problema a una sola dimensión espacial, puesto que  $M_s$  no depende de  $y$ , se puede resolver la primera integral y escribir:

$$V_{\text{pixel}} = \int_0^{T_{\text{exp}}} \int_{z_p}^{z_p+l_p} M(z, t) dz dt \quad (3.12)$$

donde  $M(z, t) = l_p M_s(z, t)$

Para facilitar el desarrollo se aplica el teorema de superposición (el problema que se está tratando es lineal). Por lo tanto, se buscan dos funciones adecuadas,  $M_{\text{fondo}}$  y  $M_{\text{mancha}}$ , tales que verifiquen  $M(z, t) = M_{\text{fondo}}(z, t) + M_{\text{mancha}}(z, t)$ ; así, la ecuación (3.12) queda de la siguiente forma:

$$V_{\text{pixel}} = \int_0^{T_{\text{exp}}} \int_{z_p}^{z_p+l_p} M_{\text{fondo}}(z, t) dz dt + \int_0^{T_{\text{exp}}} \int_{z_p}^{z_p+l_p} M_{\text{mancha}}(z, t) dz dt = V_{\text{pixel}}^{\text{fondo}} + V_{\text{pixel}}^{\text{mancha}} \quad (3.13)$$

Las mencionadas funciones en que se descompone la función exitancia son:

$$M_{\text{fondo}} = M_2 \frac{W}{\text{cm}^2} \quad \forall z \quad (3.14)$$

$$M_{\text{mancha}} = \left\{ \begin{array}{ll} M_1 - M_2 & \text{si } z \in (z(t), z(t) + l_m) \\ 0 & \text{e.o.c.} \end{array} \right\} \frac{W}{\text{cm}^2}$$

Como  $M_1 < M_2$ ,  $M_{\text{mancha}}$  tiene un valor negativo si  $z$  pertenece a la mancha. Por lo tanto, de forma ficticia,  $M_{\text{mancha}}$  descarga el píxel. Esta descomposición no es única; se han escogido esas funciones porque, además de, verificar que su suma es igual a  $M(z, t)$ , también se simplifica el problema.  $M_{\text{fondo}}$  no está definida a trozos y su contribución al valor del píxel es inmediata:

$$V_{\text{pixel}}^{\text{fondo}} = M_2 l_p T_{\text{exp}} \quad (3.15)$$

Además, aunque el cálculo de la contribución de la mancha es un poco más engorrosa, y similar al problema completo, tiene la ventaja que si un punto  $z$  no pertenece a la mancha su exitancia es 0.

Para calcular  $V_{\text{pixel}}^{\text{mancha}}$  es necesario definir una serie de intervalos temporales. En cada uno de ellos el píxel “verá” algo diferente, en función del avance de la plancha.

En la figura 3.11 se muestran gráficamente estos intervalos para  $l_p > l_m$ , y están definidos matemáticamente de la siguiente forma:

- Intervalo 1. En él, la mancha aún no es vista por el píxel (figura 3.11 (a)).  $t_1$  es el tiempo transcurrido desde la posición inicial de la mancha hasta que el extremo derecho de la mancha llega al inicio del píxel. En este intervalo, la mancha llega al borde del píxel:

$$z_m(t) + l_m \leq z_p \quad (3.16)$$

Teniendo en cuenta (3.9) y despejando  $t$ , queda:

$$t \leq \frac{z_p - z_{m0} - l_m}{v_{lam}} = t_1 \quad (3.17)$$

Para independizar los resultados de la posición inicial de la mancha y del tamaño del píxel, se introducirá una nueva notación:

$$z_p - z_{m0} = \Delta \quad (3.18)$$

Así,  $\Delta$  es el desfase entre el píxel y la mancha cuando comienza la exposición. Entonces,  $t_1$  queda con la nueva notación:

$$t_1 = \frac{\Delta - l_m}{v_{lam}} \quad (3.19)$$

- Intervalo 2. La mancha es vista por el píxel a medida que va entrando (figura 3.11 (b)).  $t_2$  es el tiempo transcurrido desde la posición inicial de la mancha hasta que el extremo izquierdo de la mancha llega al inicio del píxel. En este intervalo, la mancha entra en el píxel. De forma más resumida:

$$\left\{ \begin{array}{l} z_m(t) + l_m > z_p \\ z_m(t) \leq z_p \end{array} \right\} \implies \left\{ \begin{array}{l} t > t_1 \\ t \leq \frac{z_p - z_{m0}}{v_{lam}} = \frac{\Delta}{v_{lam}} = t_2 \end{array} \right\} \quad (3.20)$$

- Intervalo 3. La mancha es vista completamente por el píxel (figura 3.11 (c)).  $t_3$  es el tiempo transcurrido desde la posición inicial de la mancha hasta que

el extremo derecho de la mancha llega al final del píxel. En este intervalo, la mancha está dentro del píxel:

$$\left\{ \begin{array}{l} z_m(t) > z_p \\ z_m(t) + l_m \leq z_p + l_p \end{array} \right\} \implies \left\{ \begin{array}{l} t > t_2 \\ t \leq \frac{\Delta + l_p - l_m}{v_{iam}} = t_3 \end{array} \right\} \quad (3.21)$$

- Intervalo 4. El píxel sigue viendo la mancha a medida que va saliendo (figura 3.11 (d)).  $t_4$  es el tiempo transcurrido desde la posición inicial de la mancha hasta que el extremo izquierdo de la mancha llega al final del píxel. En este intervalo la mancha sale del píxel:

$$\left\{ \begin{array}{l} z_m(t) + l_m > z_p + l_p \\ z_m(t) \leq z_p + l_p \end{array} \right\} \implies \left\{ \begin{array}{l} t > t_3 \\ t \leq \frac{\Delta + l_p}{v_{iam}} = t_4 \end{array} \right\} \quad (3.22)$$

- Intervalo 5. La mancha deja de ser vista por el píxel (figura 3.11 (e)):

$$z_m(t) > z_p + l_p \implies t > t_4 \quad (3.23)$$

Una vez definidos los intervalos, se puede integrar en la dimensión espacial el segundo sumando de (3.13); por supuesto, el resultado dependerá del intervalo en el que se esté en cada momento:

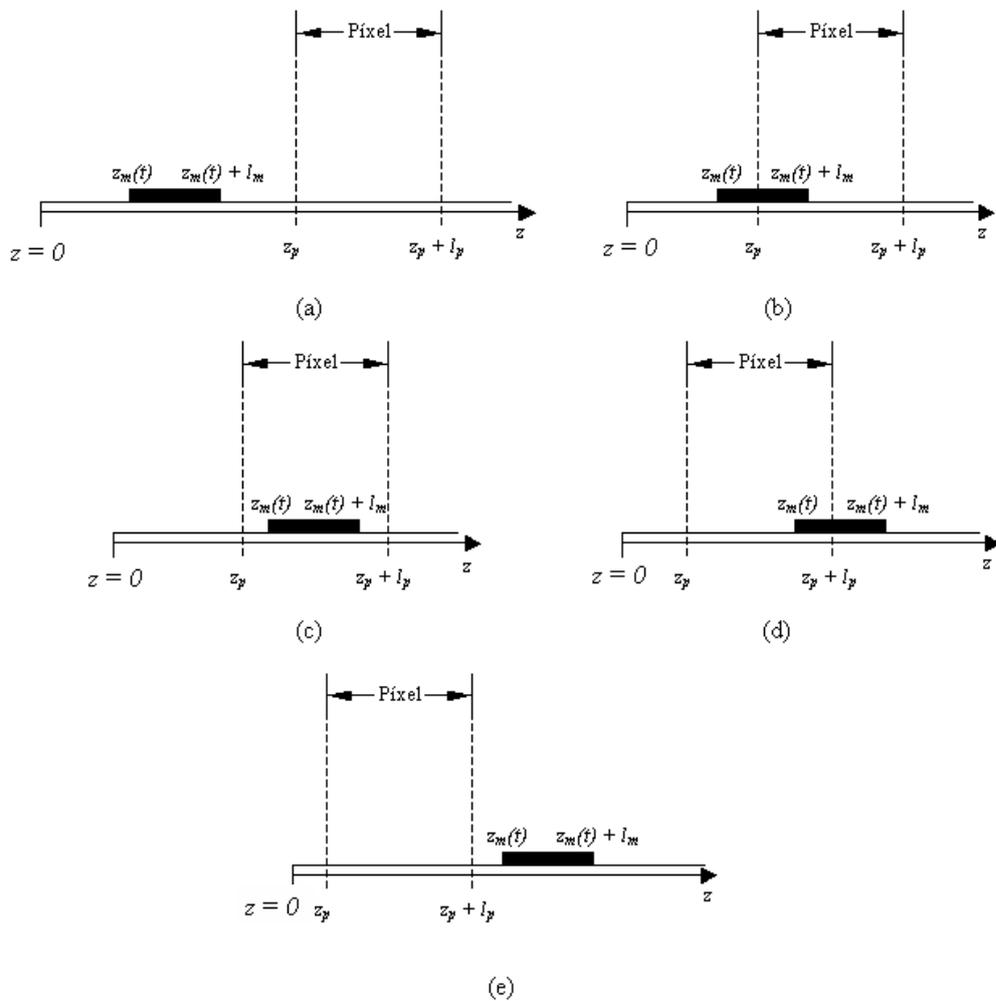
$$\begin{aligned} V_{\text{píxel}}^{\text{mancha}}(t) &= \int_{z_p}^{z_p+l_p} M_{\text{mancha}}(z, t) dt dz = \\ &= \left\{ \begin{array}{ll} 0 & \text{si } t \leq t_1 \\ M'[z_m(t) + l_m - z_p] & \text{si } t_1 < t \leq t_2 \\ M' l_m & \text{si } t_2 < t \leq t_3 \\ M'[z_p + l_p - z_m(t)] & \text{si } t_3 < t \leq t_4 \\ 0 & \text{si } t > t_4 \end{array} \right\} \end{aligned} \quad (3.24)$$

$M'$  es, por simplificar la formulación,  $M_1 - M_2$

El objetivo es calcular el valor del píxel en función del tiempo de integración, por lo que se tienen cinco casos dependiendo de en qué intervalo se encuentre  $T_{exp}$ . Seguidamente se estudia caso por caso:

1. Caso  $T_{exp} \leq t_1$ .

$$V_{\text{píxel}}^{\text{mancha}} = \int_0^{T_{exp}} [V_{\text{píxel}}^{\text{mancha}}(t)]_{t \leq t_1} dt = 0 \quad (3.25)$$



**Figura 3.11:** Intervalos temporales en el estudio teórico del tiempo de exposición (a) Mancha no ha llegado al píxel, (b) Mancha antes de ser vista completamente, (c) Mancha vista completamente, (d) Mancha después de ser vista completamente, (e) Mancha ha pasado del píxel

2. Caso  $t_1 < T_{exp} \leq t_2$ .

$$\begin{aligned}
 V_{\text{pixel}}^{\text{mancha}} &= \int_0^{T_{exp}} V_{\text{pixel}}^{\text{mancha}}(t) dt = & (3.26) \\
 &= \int_0^{t_1} [V_{\text{pixel}}^{\text{mancha}}(t)]_{t \leq t_1} dt + \int_{t_1}^{T_{exp}} [V_{\text{pixel}}^{\text{mancha}}(t)]_{t_1 < t \leq t_2} dt = \\
 &= M' \int_{t_1}^{T_{exp}} [z_m(t) + l_m - z_p] dt = \\
 &= M' [(z_{m0} - z_p + l_m)(T_{exp} - t_1) + \frac{v_{lam}(T_{exp}^2 - t_1^2)}{2}]
 \end{aligned}$$

Teniendo en cuenta (3.18) y (3.19) y agrupando:

$$V_{\text{pixel}}^{\text{mancha}} = M' \left[ \frac{v_{lam} T_{exp}^2}{2} + (l_m - \Delta) T_{exp} + \frac{(\Delta - l_m)^2}{2v_{lam}} \right] \quad (3.27)$$

3. Caso  $t_2 < T_{exp} \leq t_3$ .

$$\begin{aligned}
 V_{\text{pixel}}^{\text{mancha}} &= M' \left[ \int_{t_1}^{t_2} [z_m(t) + l_m - z_p] dt + \int_{t_2}^{T_{exp}} l_m dt \right] = & (3.28) \\
 &= M' \left[ (l_m - \Delta)(t_2 - t_1) + \frac{v_{lam}(t_2^2 - t_1^2)}{2} + l_m (T_{exp} - t_2) \right]
 \end{aligned}$$

Sustituyendo los valores de  $t_1$  y  $t_2$  (ecuaciones (3.19) y (3.20)), queda el siguiente resultado:

$$V_{\text{pixel}}^{\text{mancha}} = M' \left[ l_m T_{exp} + \frac{l_m^2}{2v_{lam}} - \frac{l_m \Delta}{v_{lam}} \right] \quad (3.29)$$

4. Caso  $t_3 < T_{exp} \leq t_4$ .

$$V_{\text{pixel}}^{\text{mancha}} = M' \left[ \int_{t_1}^{t_2} [z_m(t) + l_m - z_p] dt + \int_{t_2}^{t_3} l_m dt + \int_{t_3}^{T_{exp}} [z_p + l_p - z_m(t)] dt \right] \quad (3.30)$$

Y directamente se obtiene, tras incluir los valores de  $t_i$  y reorganizar:

$$V_{\text{pixel}}^{\text{mancha}} = M' \left[ -\frac{v_{lam} T_{exp}^2}{2} + (l_p + \Delta) T_{exp} + \frac{l_p l_m}{v_{lam}} - \frac{(l_p + \Delta)^2}{2v_{lam}} \right] \quad (3.31)$$

5. Caso  $t_4 < T_{exp}$ .

$$V_{\text{pixel}}^{\text{mancha}} = M' \left[ \int_{t_1}^{t_2} [z_m(t) + l_m - z_p] dt + \int_{t_2}^{t_3} l_m dt + \int_{t_3}^{t_4} [z_p + l_p - z_m(t)] dt \right] \quad (3.32)$$

Y operando queda:

$$V_{pixel}^{mancha} = M' \frac{l_p l_m}{v_{lam}} \quad (3.33)$$

Con lo cual, sin más que sumar (3.15) a  $V_{pixel}^{mancha}$  se tiene el valor del píxel para cualquier valor de  $T_{exp}$ .

El desarrollo en caso que  $l_p < l_m$  es similar. Realizando un análisis idéntico al ya visto para definir los extremos de los intervalos (ecuaciones (3.16) a (3.23)), se llega a los mismos tiempos de separación, pero en este caso  $t_1 < t_3 < t_2 < t_4$ . En este caso  $t_2$  es mayor que  $t_3$  debido a que al ser más grande la mancha que el píxel, el extremo derecho de la mancha llega antes al final del píxel que el extremo izquierdo de la mancha al inicio del píxel. Así pues, sin repetir aquí el desarrollo:

1. Caso  $T_{exp} \leq t_1$ .

$$V_{pixel} = l_p M_2 T_{exp} \quad (3.34)$$

2. Caso  $t_1 < T_{exp} \leq t_3$ .

$$V_{pixel} = M' \frac{v_{lam} T_{exp}^2}{2} + [M' (l_m - \Delta) + M_2 l_p] T_{exp} + M' \frac{(\Delta - l_m)^2}{2v_{lam}} \quad (3.35)$$

3. Caso  $t_3 < T_{exp} \leq t_2$ .

$$V_{pixel} = M_1 l_p T_{exp} + M' \left( \frac{l_p l_m}{v_{lam}} - \frac{l_p^2}{2v_{lam}} - \frac{l_p \Delta}{v_{lam}} \right) \quad (3.36)$$

4. Caso  $t_2 < T_{exp} \leq t_4$ .

$$V_{pixel} = -M' \frac{v_{lam} T_{exp}^2}{2} + [M' (l_p + \Delta) + M_2 l_p] T_{exp} + M' \left[ \frac{l_p l_m}{v_{lam}} - \frac{(l_p + \Delta)^2}{2v_{lam}} \right] \quad (3.37)$$

5. Caso  $t_4 < T_{exp}$ .

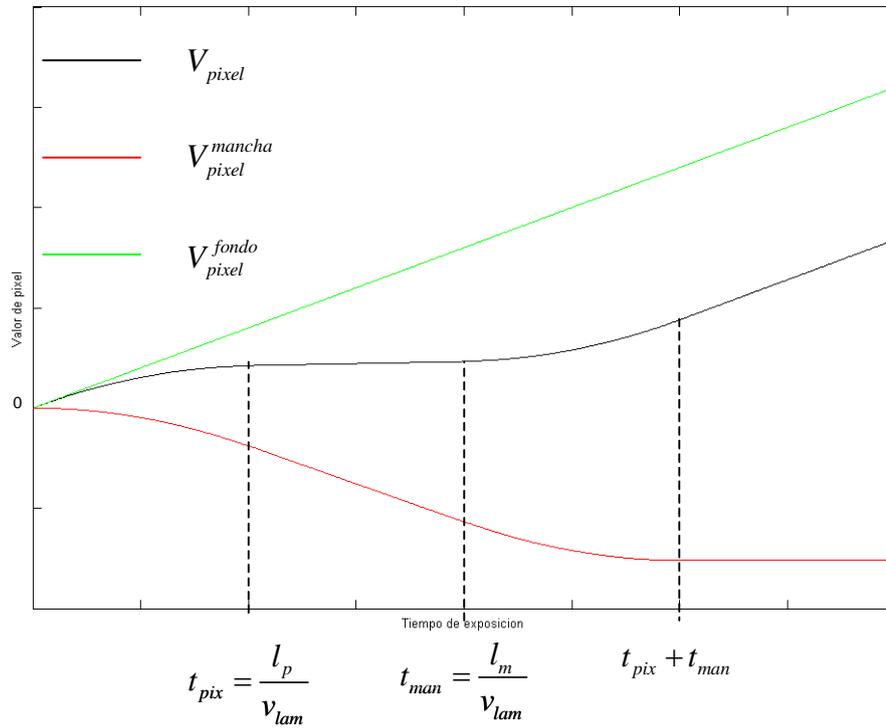
$$V_{pixel} = M' \frac{l_p l_m}{v_{lam}} + M_2 l_p T_{exp} \quad (3.38)$$

Para obtener conclusiones del modelo teórico, se representa en una gráfica  $V_{\text{píxel}}$  en un caso particular:  $\Delta = l_m$  (o lo que es lo mismo,  $t_1 = 0$ ) y  $l_m = 2l_p$ . Es decir,  $\Delta = l_m$  significa que para  $t = 0$ , el borde derecho de la mancha coincide con el borde izquierdo del píxel. En la figura 3.12 se encuentran representados  $V_{\text{píxel}}^{\text{fondo}}$ ,  $V_{\text{píxel}}^{\text{mancha}}$  y  $V_{\text{píxel}}$  en el mencionado caso. Analizando  $V_{\text{píxel}}^{\text{mancha}}$  se puede observar:

- La máxima pendiente (negativa, puesto que  $V_{\text{píxel}}^{\text{mancha}}$  tiene valores negativos o 0) se encuentra en el intervalo  $(t_3, t_2)$ , cuando la mancha es vista completamente por el píxel.
- En el intervalo  $(t_1, t_3)$  la pendiente del valor del píxel decrece con la misma pendiente con la que crece en el  $(t_2, t_4)$ , ya que la mancha “entra y sale” del píxel a la misma velocidad  $v_{\text{lam}}$ .
- A partir de  $t_4$  la curva no decrece más, puesto que en  $M_{\text{mancha}}$  el fondo no emite luz. Si se mira a  $V_{\text{píxel}}$ , lo que ocurre es que a partir de este punto el crecimiento se debe al fondo y no a la mancha, por lo que cuanto mayor sea  $T_{\text{exp}}$  con respecto a  $t_4$  más distorsionada quedará la información de la mancha.

En la figura 3.13 se encuentran representadas varias curvas de  $V_{\text{píxel}}$  para varios valores de  $l_m$  y con la misma posición inicial que anteriormente ( $\Delta = l_m$  o  $t_1 = 0$ ). La curva negra es el caso  $l_m = 2l_p$ . En el caso  $l_p > l_m$ , conforme  $l_m$  va siendo más pequeña, la curva se va pareciendo más a la de carga debida únicamente al fondo (línea punteada). La curva magenta corresponde al caso en que la mancha tiene un tamaño igual a un tercio del tamaño del píxel, y como se puede apreciar en la figura, en ella casi no se nota el efecto de la mancha.

El siguiente paso es introducir más de un píxel en el caso  $l_m = 2l_p$ . La posición inicial de la mancha es tal que está “a punto de ser vista por un píxel”. Entonces, si hubiera un píxel adyacente al estudiado hasta ahora, en el instante inicial “estaría viendo a la mancha”. A continuación se va a tratar esta situación, con la extensión



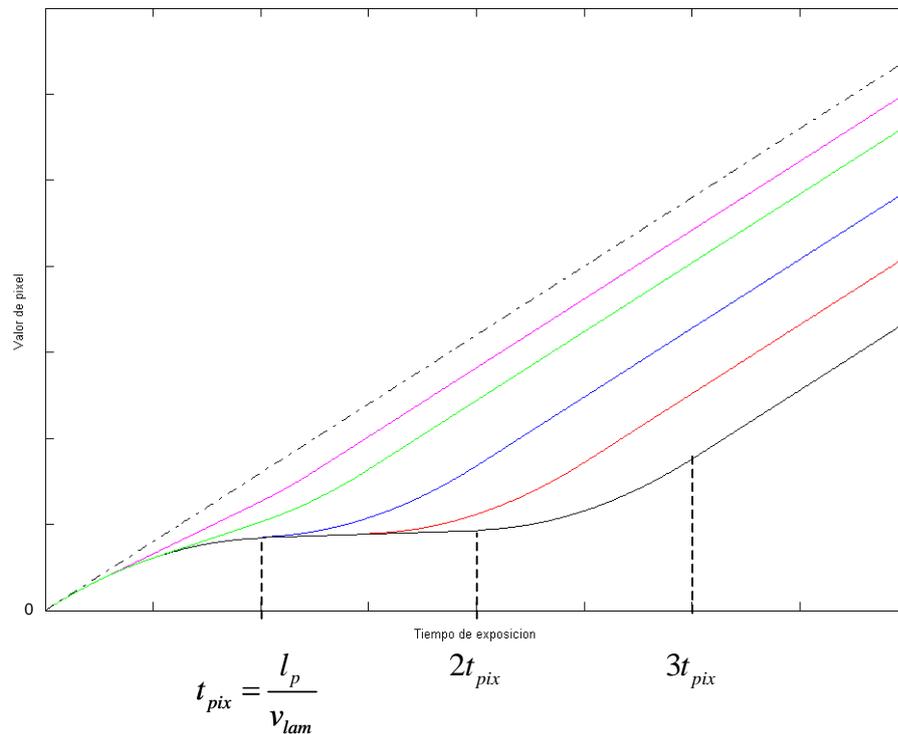
**Figura 3.12:** Representación del valor del píxel en función del tiempo de exposición (Caso particular:  $\Delta = l_m$  y  $l_m = 2l_p$ )

del modelo a varios píxeles. Pero, no hay que repetir ningún cálculo, ya que éste es el mismo caso anterior con diferente  $z_{m0}$  o  $\Delta$ .

En la figura 3.14 se encuentra representada la situación inicial para  $n$  píxeles, que se nombrarán de ahora en adelante como  $P_1, P_2, \dots, P_n$ .

El valor de  $\Delta$  para cada uno de los píxeles será:

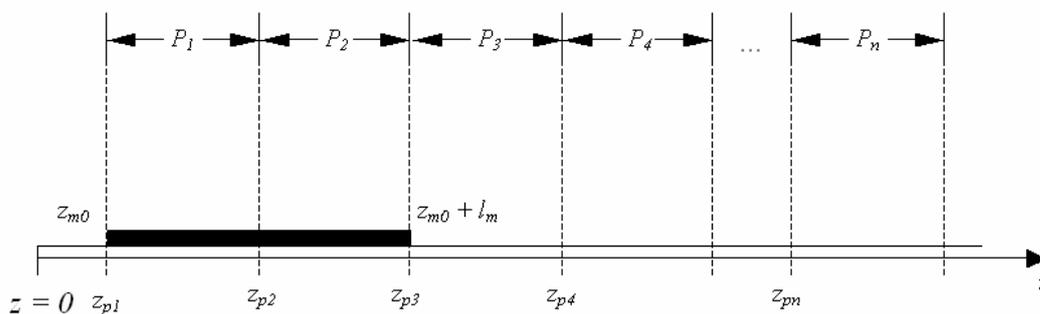
$$\left\{ \begin{array}{l} \Delta_1 = 0 \\ \Delta_2 = l_p \\ \Delta_3 = l_m \\ \Delta_4 = l_m + l_p \\ \Delta_5 = l_m + 2l_p \\ \dots \\ \Delta_n = l_m + (n - 3) l_p \end{array} \right\} \quad (3.39)$$



**Figura 3.13:** Contribución de la mancha al valor del píxel para distintos tamaños de  $l_m$  (Condiciones iniciales:  $\Delta = l_m$  ó  $t_1 = 0$ )

Si se representan los valores de los píxeles en una misma gráfica (figura 3.15), se pueden extraer las siguientes conclusiones de la extensión del modelo a varios píxeles:

- Conforme mayor sea el tiempo de exposición mayor será el valor que alcanzará cada píxel. Si es lo suficientemente grande, se alcanzará la saturación en el píxel enmascarando completamente la información.
- Otra consecuencia de permitir un tiempo de exposición elevado es que la mancha en la imagen ocupará más píxeles de los que debería ocupar por su tamaño. Idealmente (plancha parada) la mancha sólo debería ser vista por los píxeles  $P_1$  y  $P_2$  (ver figura 3.14); sin embargo, si el tiempo de exposición es por ejemplo



**Figura 3.14:** Situación inicial de la mancha en la extensión del modelo a varios píxeles

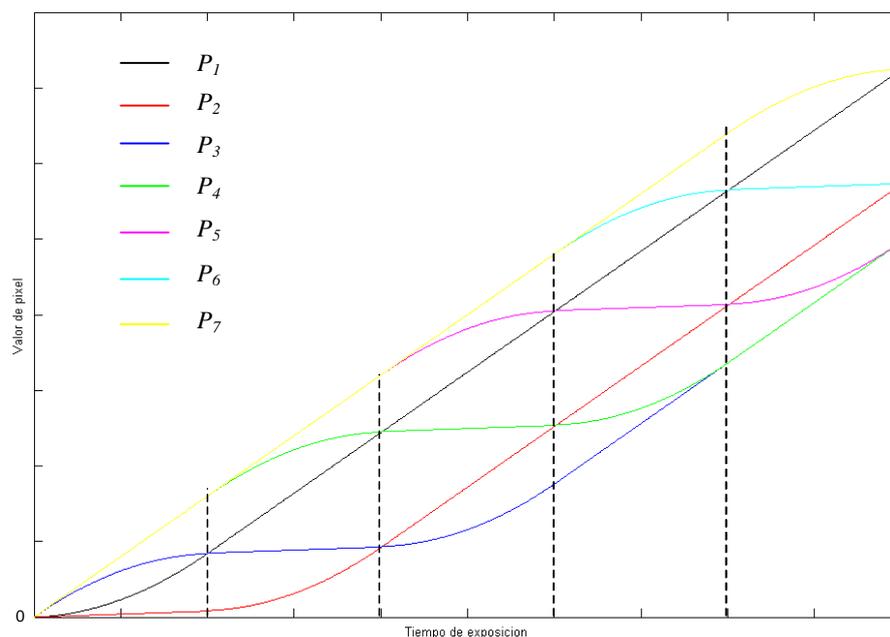
$t_{pix}$  (y con la plancha en movimiento),  $P_3$  tendrá el mismo valor que  $P_1$ , y  $P_2$  un valor menor que ambos. Por tanto, habrá tres píxeles que no serán fondo (posteriormente, serán interpretados como fondo o mancha dependiendo del procesado).

- También se observa que la diferencia entre el píxel de menor valor y el de mayor es la misma, si el tiempo de exposición es mayor que  $t_{man} + t_{pix}$ .

Todas estas conclusiones han sido extraídas suponiendo una iluminación constante y arbitraria, cuando eso no será cierto en la práctica. Realmente, se trata de ajustar para que los píxeles más brillantes saturen, o queden cerca de la saturación para aprovechar todo el rango dinámico del sensor. Por tanto, se normalizan las ecuaciones (3.34) a (3.38) respecto al píxel que alcance mayor valor. El factor de normalización es:

$$g_{norm} = \frac{V_{saturación}}{V_{píxel|máximo}} \quad (3.40)$$

No obstante,  $V_{píxel|máximo}$  es función del tiempo de exposición, como se puede apreciar en la figura 3.15, y parece en principio que no es posible representar las curvas normalizadas. Sin embargo, en el caso que nos ocupa el máximo siempre corresponde a píxeles de fondo. Por tanto, teniendo en cuenta (3.15) y (3.40),  $g_{norm}$



$$t_{pix} = \frac{l_p}{v_{lam}} \quad t_{man} = \frac{l_m}{v_{lam}} \quad t_{man} + t_{pix} \quad t_{man} + 2t_{pix}$$

**Figura 3.15:** Valores de los píxeles  $P_1, P_2, \dots, P_n$  en función del tiempo de exposición

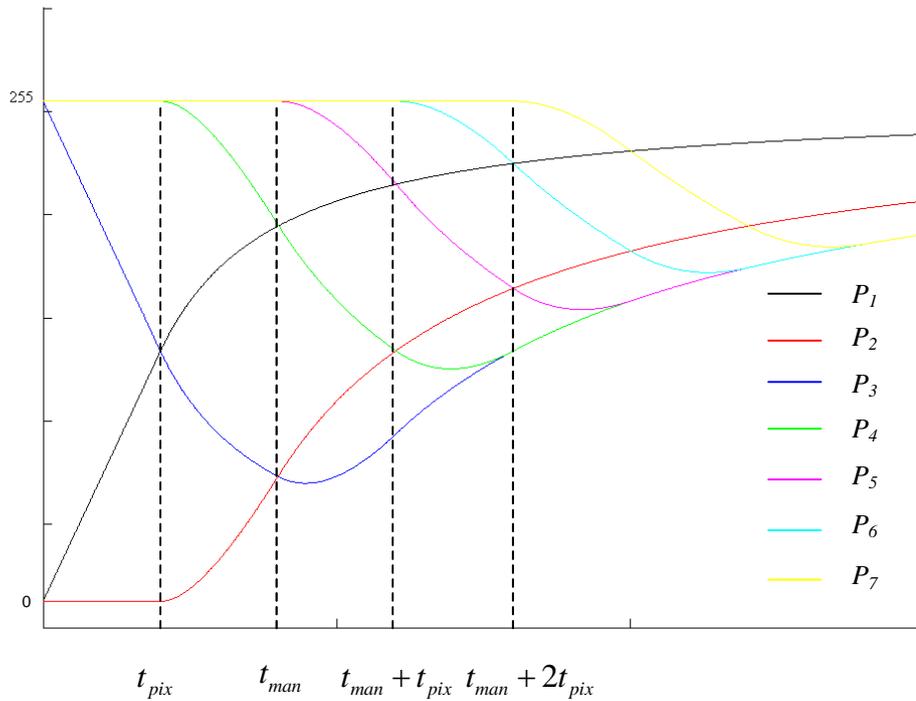
es equivalente a:

$$g_{norm} = \frac{V_{saturación}}{V_{píxel}^{fondo}} = \frac{V_{saturación}}{M_2 l_p T_{exp}} = \frac{255}{M_2 l_p T_{exp}} \quad (3.41)$$

Por conveniencia,  $V_{saturación}$  se toma igual a 255, ya que, más adelante se realiza una simulación en la que se representan los valores de los píxeles obtenidos de las ecuaciones como imágenes (en las cámaras estándar, cada píxel de una imagen posee 255 niveles de gris, debido a que la señal analógica de video se digitaliza con un conversor A/D de 8 bits).

El resultado de escalar  $V_{píxel}$  (para cada píxel analizado) con  $g_{norm}$  se encuentra en la figura 3.16. Ahora las conclusiones son diferentes: viendo la figura 3.15 parecía que tomar el tiempo de exposición pequeño era una desventaja, dado que el contraste era peor cuando éste disminuye. Después del ajuste, se puede apreciar que eso no

es cierto; idealmente, lo óptimo es tomar  $T_{exp} \rightarrow 0$ , como indica el sentido común. Por supuesto, en la práctica esto no es viable, puesto que para saturar los píxeles de fondo con  $T_{exp} \rightarrow 0$  se necesitaría una fuente luminosa de potencia infinita.



**Figura 3.16:** Valores normalizados de los píxeles  $P_1, P_2, \dots, P_n$  en función del tiempo de exposición

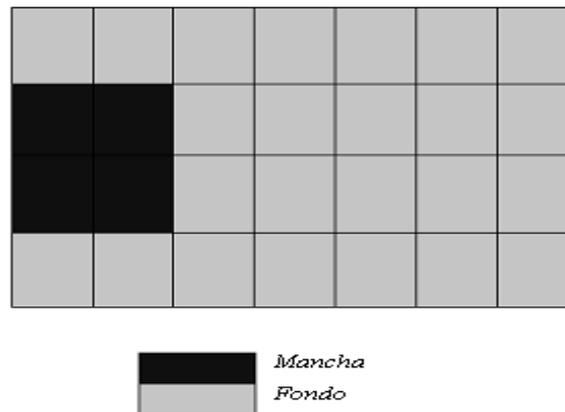
También hay que resaltar que el contraste disminuye con el aumento del tiempo de exposición, aunque no lo hace de forma significativa entre  $t_{pix}$  y  $t_{man}$ . En la tabla 3.1 se muestran los valores normalizados de los píxeles para diferentes tiempos de exposición.

Con todo ello, parece adecuado tomar como tiempo de exposición válido  $t_{pix}$  (que es el tiempo que tarda un punto del eje  $z$  en pasar por un píxel). Aunque se puede aumentar a  $t_{man}$ , que es, en el peor de los casos, el doble de  $t_{pix}$  y aún mantiene su contraste.

	Valores normalizados de los píxeles						
	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$	$P_6$	$P_7$
$t_{pix}$	133	12	133	255	255	255	255
$t_{man}$	194	73	73	195	255	255	255
$t_{pix} + t_{man}$	214	133	93	134	215	255	255
$2t_{man}$	224	164	133	133	164	225	255

**Tabla 3.1:** Valores normalizados de los píxeles para varios tiempos de exposición

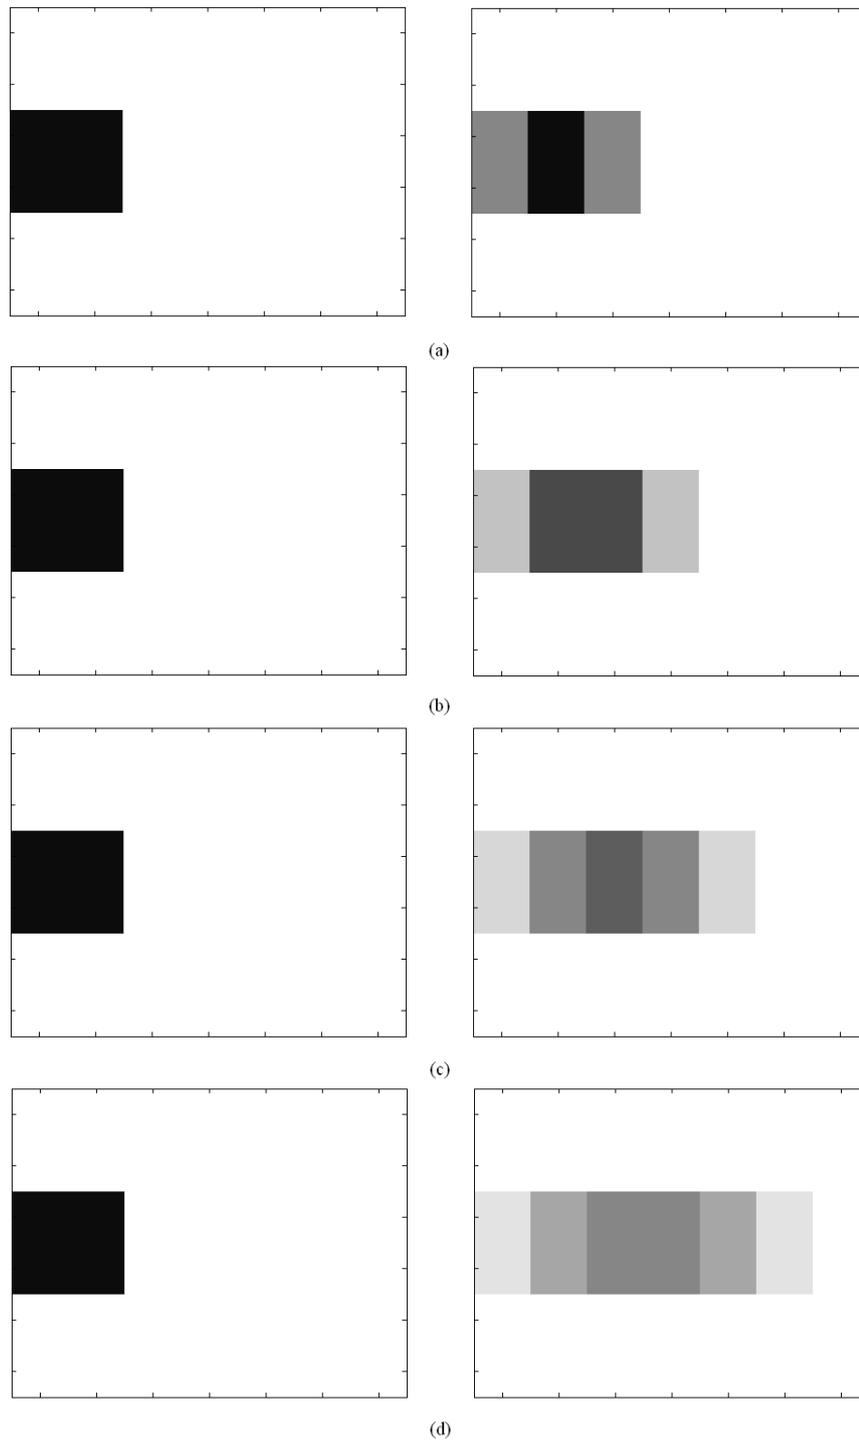
Para apreciar todo lo mostrado de la forma más parecida a como se verá realmente, también se han representado los valores de los píxeles obtenidos con las ecuaciones como si fueran una imagen. La imagen de referencia es una matriz de 7 x 4 como la que se muestra en la figura 3.17. Las dos filas centrales son dos arrays de siete píxeles idénticos a los que se han analizado anteriormente ( $P_1, P_2, \dots, P_7$ ), y las dos restantes están formadas íntegramente por píxeles de fondo.



**Figura 3.17:** Imagen de referencia para la representación de los valores obtenidos de las ecuaciones como una imagen

Así, en la figura 3.18 se muestran las mencionadas imágenes, a plancha parada y en movimiento, para distintos valores del tiempo de exposición.

En resumen, el  $T_{exp}$  óptimo ha de ser tan pequeño como sea posible, pero es un buen compromiso  $T_{exp} = t_{pix}$ . El tamaño mínimo detectable de una mancha se ha



**Figura 3.18:** Simulación de imágenes. (a)  $T_{exp} = t_{pix}$ , (b)  $T_{exp} = t_{man}$ , (c)  $T_{exp} = t_{man} + t_{pix}$  y (d)  $T_{exp} = 2t_{man}$ . La columna de la izquierda es a plancha parada y la de la derecha con la plancha en movimiento

seleccionado entre 0,05 y 0,1mm; esto requiere que el tamaño del píxel en el plano objeto pertenezca al intervalo [0,025, 0,050] mm, para cumplir con la condición de 2 píxeles por mancha, en cada dirección. Entonces, para este intervalo resulta el siguiente tiempo de exposición:

$$T_{exp} \in \left[ \frac{l_p^{min}}{v_{lam}}, \frac{l_p^{max}}{v_{lam}} \right] \Rightarrow T_{exp} \in [25, 50] \mu s \quad (3.42)$$

También se ha comprobado que aumentarlo a  $t_{man}$  no supone en principio una pérdida de contraste elevada. El problema si se toma como válido  $T_{exp} = t_{man}$ , es que el tiempo depende del tamaño de la mancha que se esté inspeccionando, y éste es absolutamente aleatorio. Por tanto, se tomará como válido un tiempo de exposición igual al calculado con el tamaño de mancha mínimo detectable. Si éste está entre 0,05 y 0,1 mm, el tiempo de exposición ha de ser:

$$T_{exp} \in \left[ \frac{l_m^{min}}{v_{lam}}, \frac{l_m^{max}}{v_{lam}} \right] \Rightarrow T_{exp} \in [50, 100] \mu s \quad (3.43)$$

#### **3.4.1.4. Sistema de iluminación**

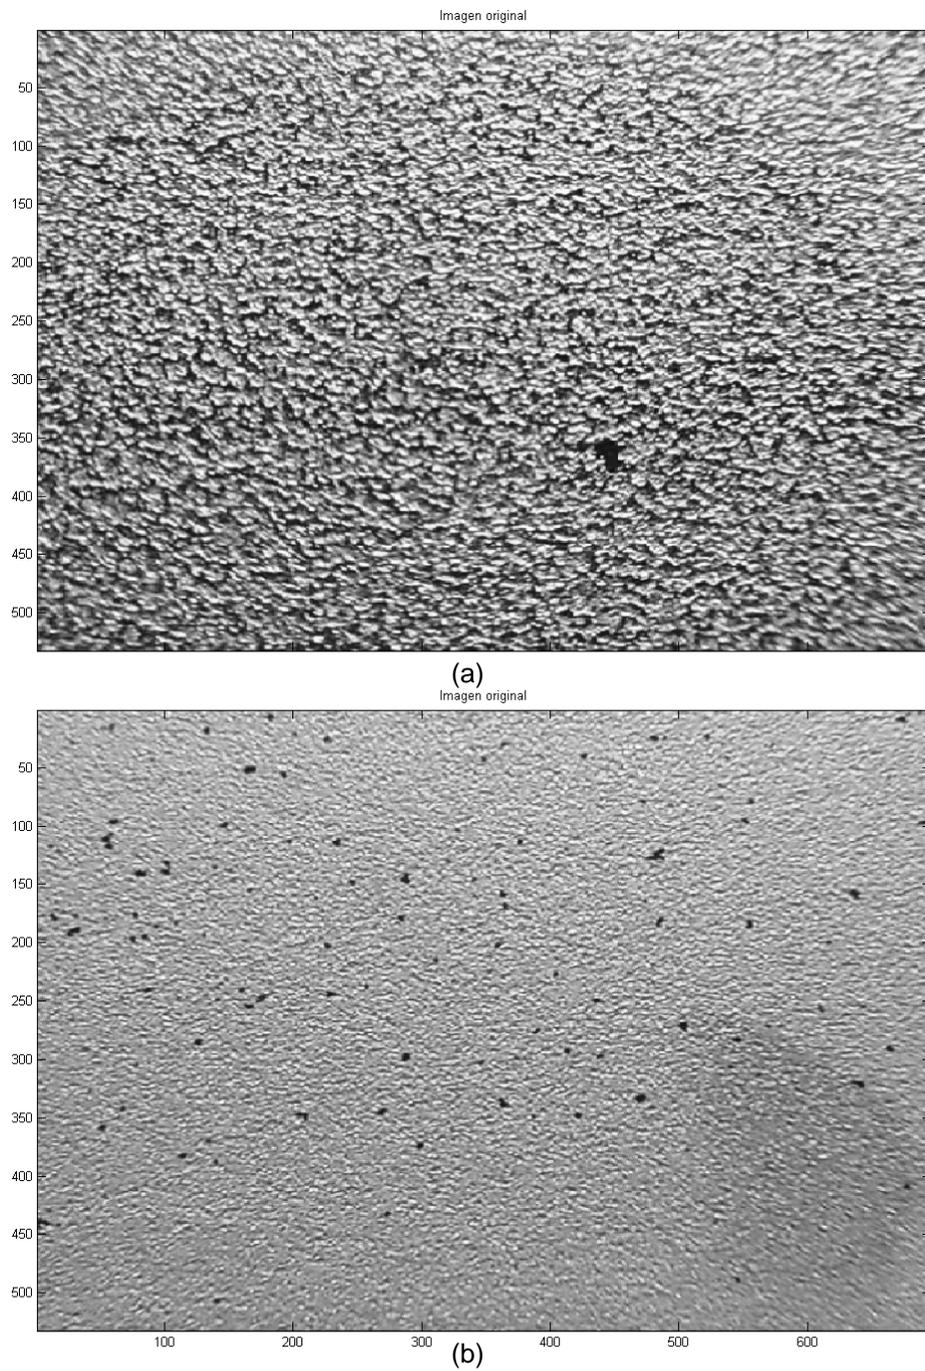
En inspección de acero inoxidable es necesario iluminación difusa, para evitar sombras, debido al grano natural de la superficie. Existen dos tipos de grano en una superficie de acero inoxidable, grueso y fino. El primero produce más sombras que el segundo. Para mostrar el efecto del grano natural del acero inoxidable, se capturan dos imágenes de acero inoxidable con iluminación oblicua convencional (figura 3.19). La figura 3.19a muestra la imagen de una plancha con acabado grueso y brillante, y la figura 3.19b otra con acabado fino y mate. Los resultados son diferentes debido al grano. En la primera imagen las sombras enmascaran los defectos de cascarilla residual. Por otro lado, el acabado brillante dificulta la inspección debido a las reflexiones y el sensor CCD de la cámara se puede saturar al aumentar la iluminación. La segunda imagen muestra correctamente los defectos de cascarilla residual debido al tipo de grano y acabado mate.

La solución es utilizar iluminación difusa en los dos casos para evitar sombras,

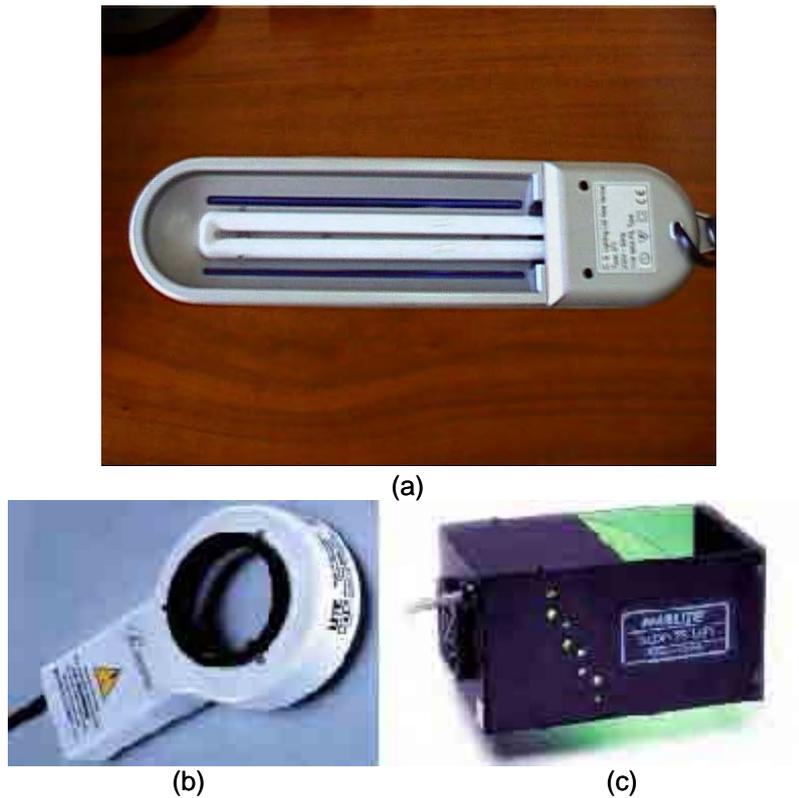
durante la inspección continua en la línea de producción.

Una aproximación a iluminación difusa, de bajo coste, se puede conseguir mediante dos tubos fluorescentes cilíndricos (figura 3.20a). De esta forma se eliminan las sombras en al menos una dirección (la paralela a los tubos). En el caso de utilizar un tubo fluorescente circular las sombras desaparecen en todas las direcciones. Pero, hay que utilizar fluorescentes de alto coste para conseguir este objetivo, debido a que los fluorescentes circulares convencionales tienen el cebador formando parte del propio fluorescente y esto provoca fuerte no uniformidad en la iluminación. En el mercado actual de iluminación existen dos tipos de fuentes de iluminación difusa apropiadas para inspección industrial, pero son delicados y de alto coste. La figura 3.20b-c muestra un ejemplo de cada tipo de fuente, la primera de la marca “Stoker & Yale” y la segunda de “Nerlite”. Una de las características adicionales de este tipo de fuentes es el control remoto de la potencia luminosa. Esto permite variar la iluminación en función del entorno (tipo de material, tipo de defectos, velocidad de captura de imagen en función de la velocidad de la línea de producción, etc.).

Brevemente comentar que en esta tesis se diseña e integra un sistema de iluminación difusa basado en láser (capítulo 4), que soluciona el problema de robustez y alto coste que presentan los sistemas convencionales actuales en el mercado.



**Figura 3.19:** (a) Imagen de una plancha de acero inoxidable brillante y grano grueso, con iluminación oblicua, (b) Ídem, pero, en este caso mate y grano fino



**Figura 3.20:** (a) Sistema de iluminación basado en tubos fluorescentes cilíndricos, (b) Anillo de luz de “Stoker & Yale”, (c) Difusor SCDI de “Nerlite”

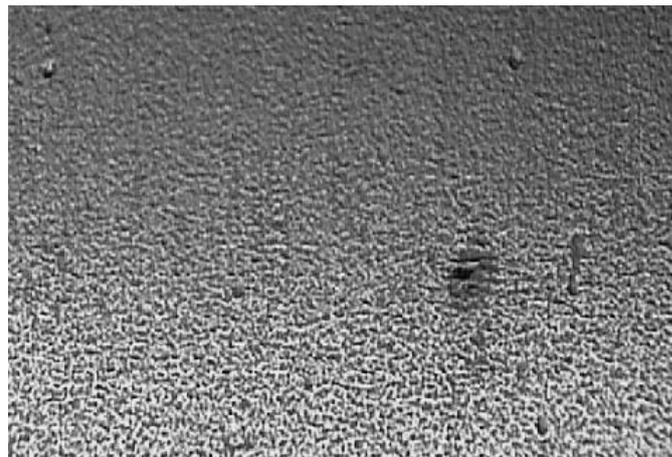
A continuación se muestran varios ejemplos de iluminación no difusa con fuentes de luz convencionales. El primero consiste en iluminar la superficie a inspeccionar sólo con una fuente de luz (fig. 3.21a). La iluminación no es adecuada para este tipo de superficie y aparecen sombras que se confunden con los defectos de cascarilla residual. Al introducir una segunda fuente de iluminación se consigue mejorar la detección de cascarilla residual en la plancha de acero inoxidable (fig. 3.21b). Por otro lado, si se desea aprovechar todo el rango dinámico de la cámara es necesario que los píxeles del fondo (acero inoxidable limpio) alcancen niveles cercanos a la saturación. Esto se consigue aumentando la potencia de la fuente luminosa, ya que el tiempo de exposición está acotado por la velocidad de la línea y el tamaño mínimo del píxel en el plano objeto (lámina de acero inoxidable a inspeccionar). Para demostrar el

efecto que se produce al saturar los píxeles de fondo se captura una imagen a plancha parada. Pero, con un tiempo de exposición elevado que permite la integración de gran cantidad de luz convencional y por tanto, aumenta el rango dinámico de las imágenes (fig. 3.21c).

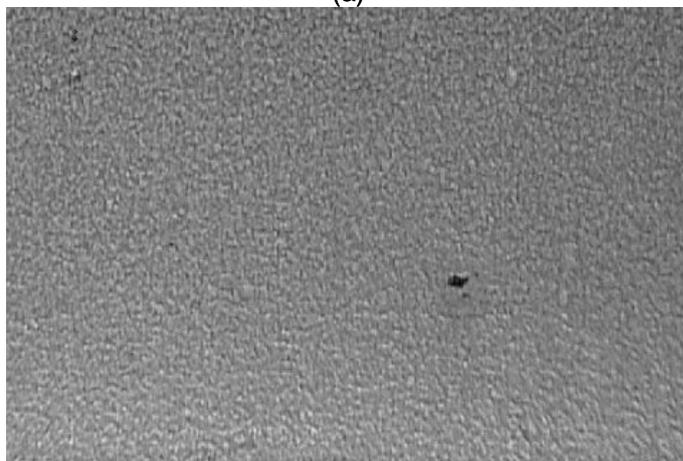
El caso ideal para un diseño industrial es una fuente de iluminación difusa de potencia elevada y una cámara que permita tiempos de exposición pequeños. Las cámaras actuales no suponen problema debido a que casi todas poseen un amplio rango de tiempos de exposición. Sin embargo, la luz proveniente de la fuente de iluminación puede ser insuficiente. Por ejemplo, los difusores transmiten sólo una fracción de la potencia de la fuente. Debido a este problema, en esta tesis se han diseñado y desarrollado dos sistemas de iluminación difusa basada en láser que iluminan con suficiente intensidad luminosa una pequeña región a inspeccionar. En el caso de iluminación láser difusa y coaxial, el haz incide sobre la plancha de forma perpendicular y minimiza la formación de sombras.

También, al necesitar un corto tiempo de exposición se puede utilizar luz pulsante. Ésta “congela” el movimiento con cortos pulsos de luz, ya que la intermitencia de la lámpara está sincronizada con la adquisición de la imagen. La duración de la fuente luminosa se alarga debido a que sólo es necesario emitir alta potencia para iluminar la superficie a inspeccionar durante un corto tiempo de exposición.

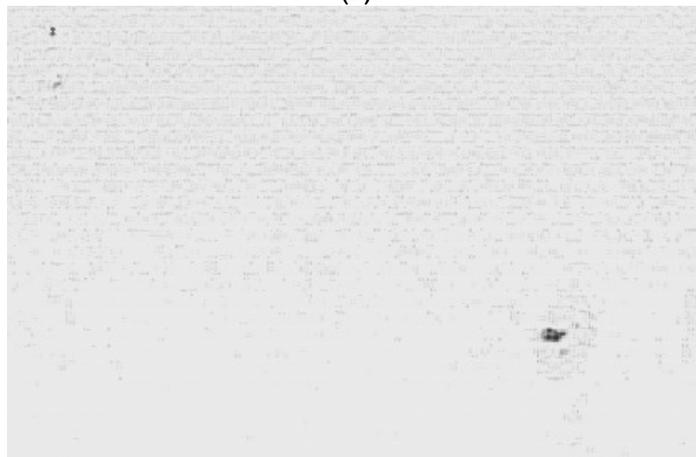
Por tanto resumiendo, la potencia luminosa es un elemento crítico en inspección industrial debido a que un sistema versátil necesita capturar imágenes de resolución variable. En el caso de detección de defectos de cascarilla residual en acero inoxidable, si se capturan imágenes con resoluciones que van desde 20 hasta 200  $\frac{\text{píxeles}}{\text{mm}}$  (tamaño mínimo detectable entre 0,01 y 0,1 mm con una cámara de 1024  $\times$  1024 píxeles), supone fotografiar cuadrados cuyos lados miden desde 50 hasta 5 mm. El lado del menor cuadrado es 10 veces más pequeño, pero su área lo es 10<sup>2</sup> veces. Además, el tiempo de exposición se reduce en el mismo factor debido a la distancia en la dirección de movimiento. Es decir, el tiempo de exposición necesario



(a)



(b)



(c)

**Figura 3.21:** (a) Imagen capturada con una única fuente de iluminación, (b) Con dos fuentes, (c) Imagen capturada con tiempo de exposición elevado para aumentar el rango dinámico de la imagen

para inspeccionar un cuadrado de lado 5 mm es 10 veces menor que el necesario para inspeccionar uno de lado 50 mm. Por tanto, un tiempo de exposición 10 veces menor requiere potencia luminosa 10 veces mayor. En total, se necesita  $10^3 = 1000$  veces más iluminación para detectar defectos superficiales de cascarilla residual de 0,010 mm que para detectarlos de 0,1 mm. Esto subraya la dificultad de la tarea de inspección superficial, y se establece el límite de inspección de defectos superficiales de cascarilla residual en la mitad (0,05 mm). En el siguiente capítulo se desarrolla un nuevo sistema de iluminación, basado en láser, que proporciona alta intensidad luminosa en la pequeña superficie a inspeccionar. Este método soluciona los problemas anteriores asociados a la iluminación convencional, permitiendo pequeños tiempos de exposición que son necesarios debido a la velocidad de la línea de producción y al microtamaño de los defectos de cascarilla residual.

#### **3.4.1.5. Capacidad de discriminación y detección de cascarilla mediante diferentes filtros ópticos**

En este apartado se analizan mediante análisis de imagen, los criterios de calidad en la discriminación de las manchas de óxido (cascarilla residual) sobre la lámina de acero inoxidable. También, se verifican las conclusiones anteriores del estudio espectrofotométrico. Es decir, se establecen criterios de calidad en la discriminación de acero inoxidable y óxido, diferenciando suficientemente la presencia de cascarilla de otro tipo de defectos o características de la superficie.

A continuación, se muestra una imagen de plancha tipo B (óxido poco apreciable a simple vista), tomada con cámara digital (figura 3.22(a)) y otra de tipo C (óxido apreciable a simple vista) (figura 3.22(b)). En la siguiente figura 3.23, se muestra una imagen típica de plancha tipo B, adquirida con lupa electrónica. Estas tres imágenes muestran la dificultad asociada a los sistemas convencionales de inspección de microdefectos de cascarilla residual en planchas de acero inoxidable; las imágenes se han capturado a plancha parada y con un elevado tiempo de exposición.



**Figura 3.22:** (a) Plancha tipo B; características de la imagen: tomada con cámara digital, RGB, sin filtro, resolución:  $2048 \times 1536$ ,  $T_{exp}$ : 0.0333 seg.,  $F/\#$ : 2.5, distancia focal: 21, sin flash y luz natural. (b) Plancha tipo C; características de la imagen: tomada con cámara digital, RGB, sin filtro, resolución  $2048 \times 1536$ ,  $T_{exp}$ : 0.025 seg.,  $F/\#$ : 2.5, distancia focal: 21, sin flash y luz natural



**Figura 3.23:** Plancha tipo B; características de la imagen: adquirida con lupa electrónica, RGB, sin filtro, resolución:  $320 \times 240$  e iluminación artificial

Y finalmente, la figura 3.24 muestra varias imágenes adquiridas con cámara digi-

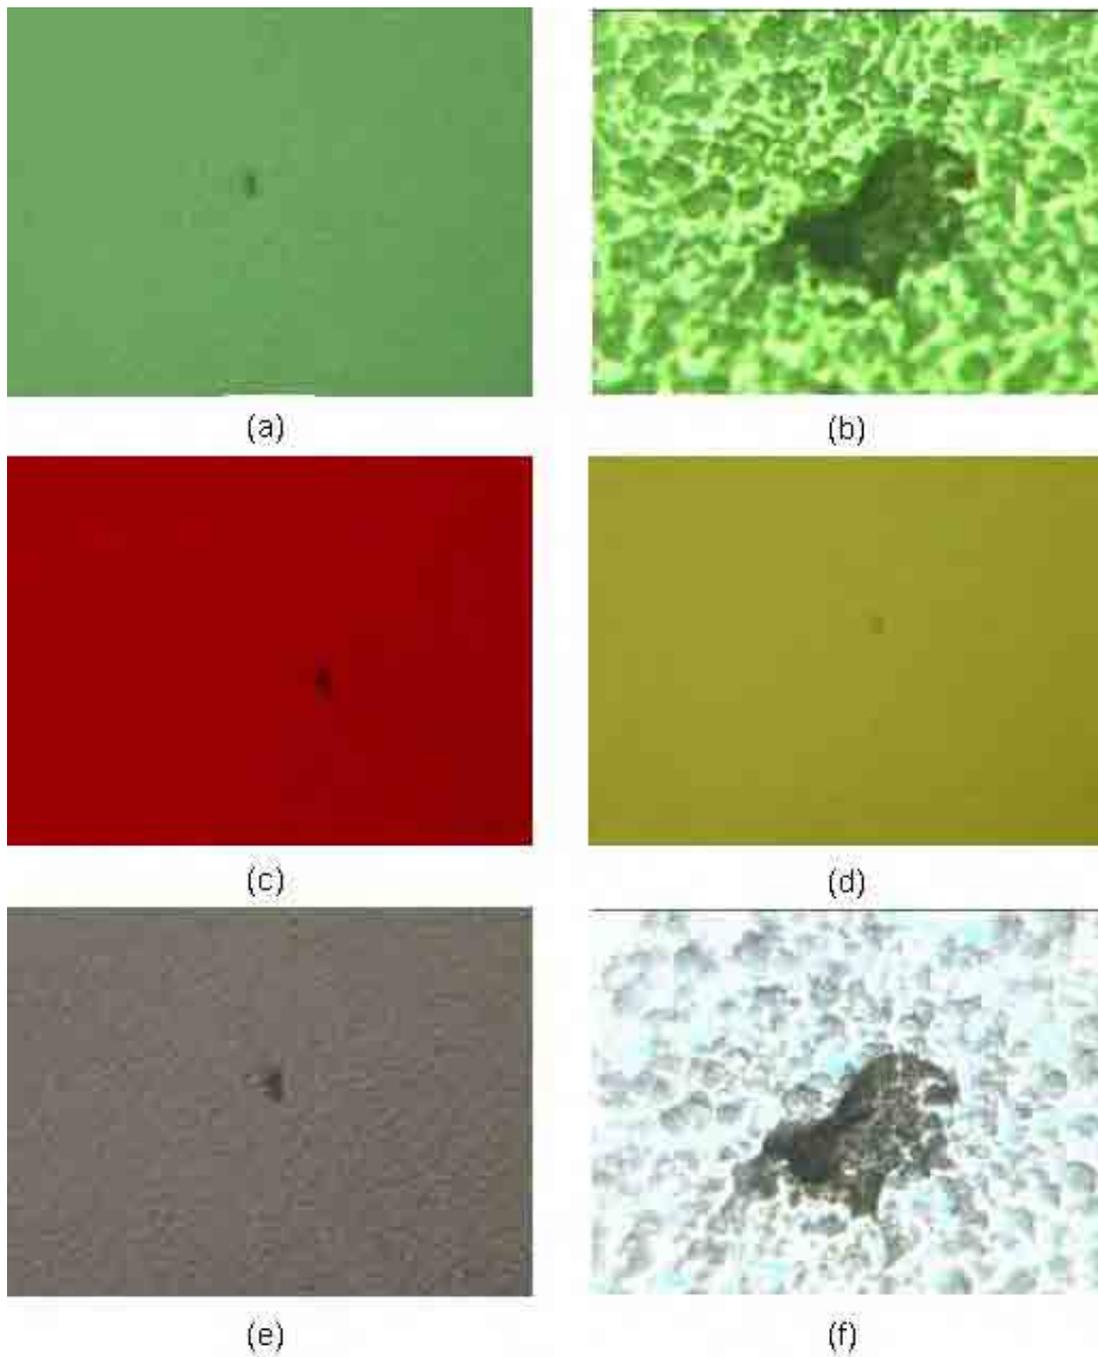
tal (resolución:  $2048 \times 1536$ ,  $T_{exp} = 0.0333$  seg.,  $F/\# = 2.5$ ,  $f = 21$ ) y lupa electrónica (resolución:  $320 \times 240$ ) en una plancha tipo C. Donde, se han utilizado los siguientes filtros: filtro verde (cámara y lupa), rojo (sólo cámara), amarillo (sólo cámara) y polarizador (cámara y lupa). En este caso, al utilizar un tiempo de exposición alto y un número  $F/\#$  pequeño, se saturan los píxeles correspondientes al acero inoxidable base. En este conjunto de experimentos se observan los defectos superficiales de cascarilla residual. También, se aprecian las diferencias entre una mancha de cascarilla y las sombras producidas por el grano natural del acero inoxidable.

En relación al estudio espectrofotométrico, donde se observó que la reflectancia en acero inoxidable es mayor que en óxido, los menores niveles de gris corresponden a óxido (cascarilla residual) y los niveles de gris más altos a acero inoxidable.

Por otro lado, una vez adquirida la imagen con los defectos de cascarilla residual, hay que detectarlos con algún método eficaz que nos permita trabajar en tiempo-real de la aplicación. En concreto se ha seleccionado un método empírico basado en crecimiento de regiones para la detección de cascarilla residual en tiempo-real. El método de crecimiento de regiones utilizado, consiste en tomar un plano de color y obtener el mínimo nivel de gris de la imagen. Seguidamente, se calculan dos umbrales cercanos al mínimo. Por ejemplo, si el mínimo valor de gris es 45, el primer umbral puede ser  $45+10=55$  y el segundo  $45+20=65$ . Debido a que, normalmente, el defecto superficial posee un rango de 10 niveles de gris.

Posteriormente, se transforma el plano de color en dos imágenes binarias utilizando los dos umbrales anteriores. La primera imagen binaria se encarga de localizar los menores niveles de gris de las manchas de cascarilla residual (semilla), eliminando imperfecciones del material o sombras. La segunda imagen al tener un umbral más alto muestra las manchas totalmente definidas, imperfecciones y sombras. Este método funciona bien en tiempo real debido a su sencillez y poco coste computacional.

Finalmente, se localiza la posición de cada píxel de cascarilla de la primera

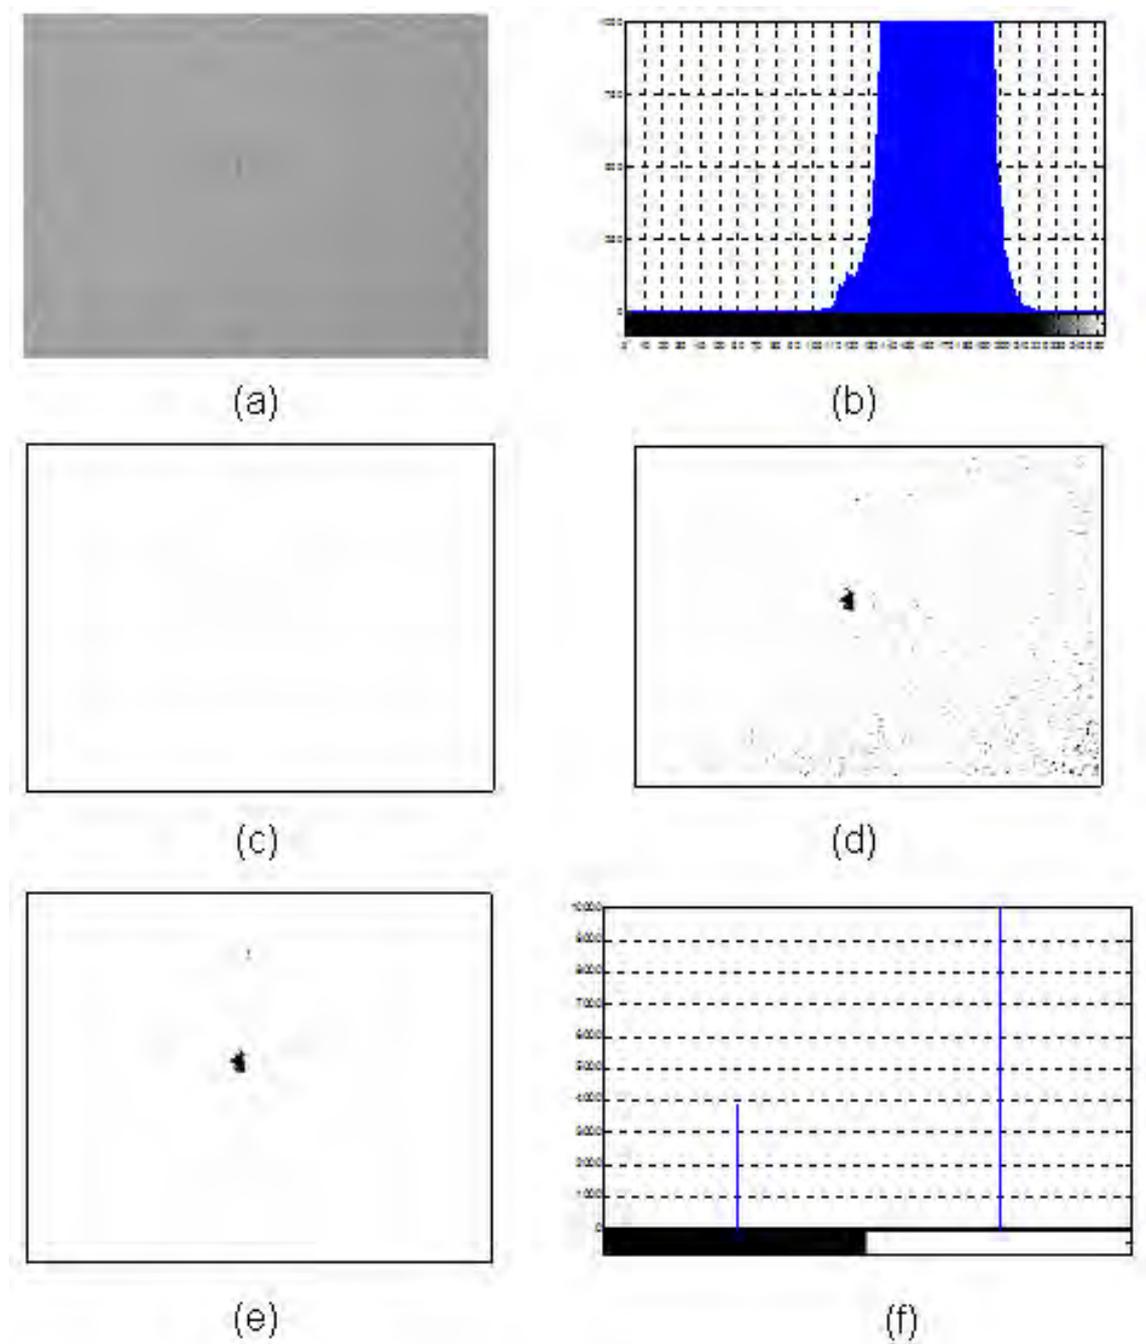


**Figura 3.24:** (a) Cámara digital, RGB, filtro verde, sin flash y luz natural; (b) Lupa electrónica, RGB, filtro verde e iluminación artificial; (c) Cámara digital, RGB, filtro rojo, sin flash y luz natural; (d) Cámara digital, RGB, filtro amarillo, sin flash y luz natural; (e) Cámara digital, RGB, filtro polarizador, sin flash y luz natural; (f) Lupa electrónica, RGB, filtro polarizador e iluminación artificial

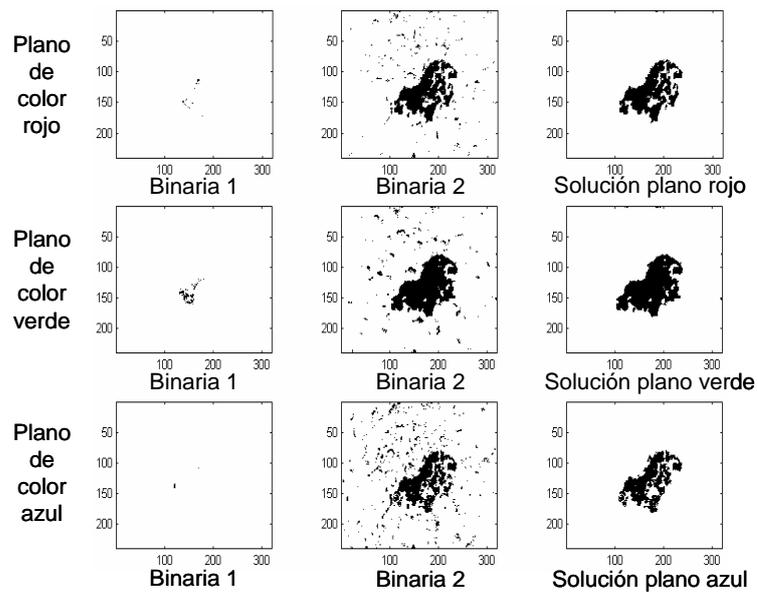
imagen binaria en la segunda imagen binaria y se hace un crecimiento desde la región del píxel semilla hasta completar la región de la mancha en la segunda imagen. De esta forma, la imagen binaria resultante contiene sólo manchas de cascarilla residual y no imperfecciones o sombras (que no tienen semillas).

Los mejores resultados se muestran en las siguientes imágenes: figuras 3.25 y 3.26, que corresponden al filtro verde (inspección con cámara y lupa electrónica); y figuras 3.27 y 3.28 al filtro polarizador (inspección con cámara y lupa electrónica). Por tanto, un sistema de visión industrial por computador para detección de cascarilla con alguno de estos dos filtros, será capaz de discriminar mejor entre cascarilla residual, y sombras e imperfecciones.

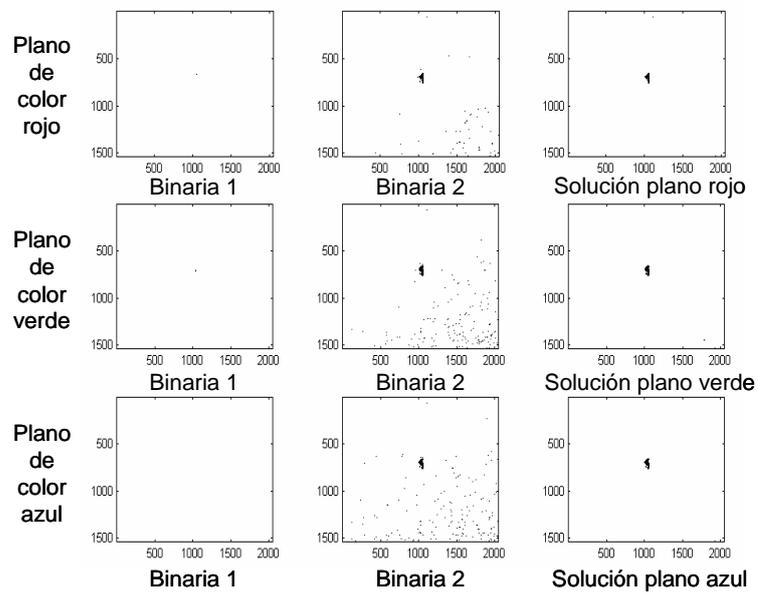
Resumiendo, en este caso a plancha parada, se saturan los píxeles de fondo para localizar bien los defectos de cascarilla residual. Pero, con la plancha en movimiento este tipo de adquisición no se puede utilizar debido a la velocidad de la línea de producción (esto produciría una imagen borrosa). Este problema de adquisición con iluminación convencional (elevado tiempo de exposición para detectar microdefectos) se soluciona en el siguiente capítulo, mediante el desarrollo de un sistema de iluminación láser que nos permite utilizar pequeños tiempos de exposición para detectar microdefectos superficiales. Es decir, en inspección de superficies en tiempo real las condiciones óptimas de adquisición de la imagen es un requisito fundamental. Una imagen correctamente adquirida, minimiza el coste computacional del sistema de inspección y permite el funcionamiento en tiempo real de la aplicación. De esta forma el tiempo de exposición, la óptica utilizada y la iluminación son componentes decisivos en inspección de superficies de laminados a alta velocidad. La experiencia en inspección industrial en tiempo-real muestra, que es más útil un sistema robusto de inspección (iluminación, óptica, cámara, etc.) que un sistema software potente.



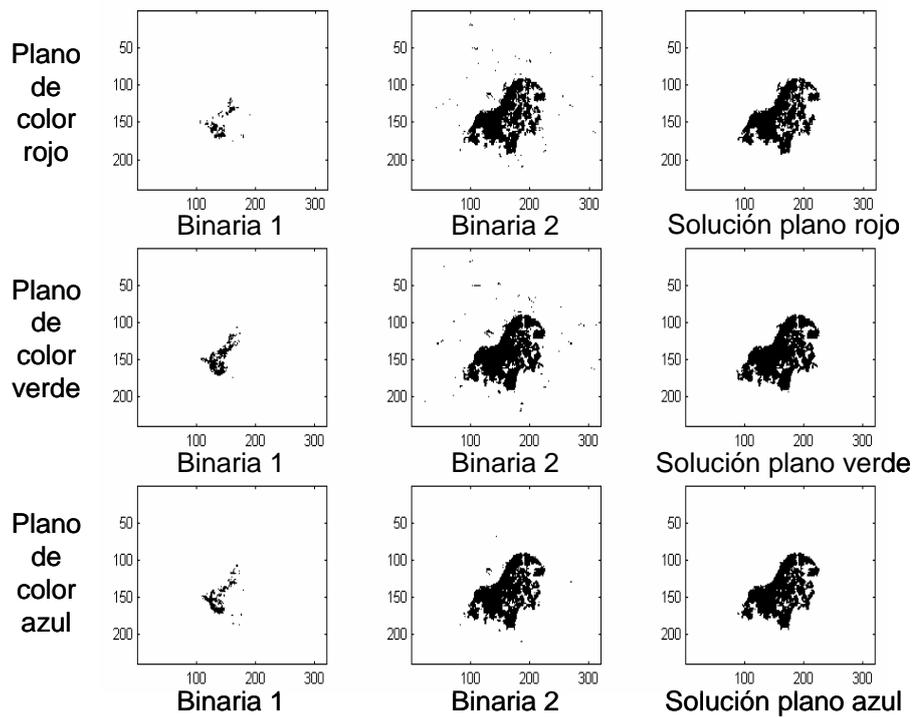
**Figura 3.25:** Plancha tipo C y cámara digital: (a) plano de color verde, (b) histograma del plano de color verde, (c) primera imagen binaria (localiza los píxeles de cascarilla residual (semillas)), (d) segunda imagen binaria con umbral mayor para detectar completamente las manchas, sombras e imperfecciones, (e) manchas de cascarilla residual y (f) histograma de la imagen binaria (e) para medir la cantidad de cascarilla



**Figura 3.26:** Plancha tipo C; Resumen de los tres planos de color, imagen tomada con lupa electrónica y filtro verde



**Figura 3.27:** Plancha tipo C. Resumen de los tres planos de color; imagen tomada con cámara digital y filtro polarizador



**Figura 3.28:** Plancha tipo C. Resumen de los tres planos de color; imagen tomada con lupa electrónica y filtro polarizador

### 3.4.2. Detección con sensor fotoeléctrico

En este apartado se aborda una metodología de detección alternativa que es capaz de resolver el problema de detección de cascarilla residual. Así pues, se expone una nueva técnica de detección basada en sensores fotoeléctricos excitados por láser.

El objetivo principal, al igual que el sistema de visión artificial, es la detección de cascarilla residual. Por otro lado, con este sistema de detección complementario se pueden comparar resultados; consiguiendo mayor fiabilidad en las conclusiones finales.

### **3.4.2.1. Descripción del sistema de detección mediante sensor fotoeléctrico**

El sistema consta de un cabezal láser el cual permite detectar manchas de óxido de 50 micras, ya que el punto de haz tiene un diámetro de 50 micras. La toma de muestras es alta, dado que posee una respuesta de alta velocidad del amplificador de 80  $\mu\text{seg}$ . Este valor es apropiado ya que está dentro del rango [50, 100]  $\mu\text{seg}$ , que se vio en el apartado anterior.

El modo de funcionamiento es el siguiente:

1. El cabezal láser envía un haz de luz (haz emitido) hacia la superficie y recibe otro haz de luz (haz reflejado), que mide la reflectancia de la superficie inspeccionada (50  $\mu\text{m}$ ). En el caso que el haz emitido incida sobre 50  $\mu\text{m}$  de acero inoxidable nos dará un valor de reflectancia diferente que si incide sobre óxido de hierro (cascarilla residual). Esto se debe, como se vio anteriormente, a que la absorción es mayor en el óxido de hierro que en el acero inoxidable y por lo tanto la reflectancia es mayor en el acero inoxidable que en el óxido de hierro.
2. Para calibrar el sensor, posicionamos el cabezal sobre la superficie de acero inoxidable con manchas de cascarilla residual, realizando varias pasadas para que se calcule automáticamente la media de las reflectancias obtenidas; a continuación situamos el haz incidente sobre una mancha apreciable a simple vista, leemos el valor de reflectancia del amplificador y ajustamos manualmente el umbral (variamos la media hacia abajo o hacia arriba, según convenga para realizar el ajuste). Así, se afina la diferencia entre óxido de hierro y acero inoxidable.
3. Finalmente, con este umbral que nos diferencia entre acero inoxidable y óxido, obtenemos una salida del amplificador de 12 voltios si la reflectancia de la superficie inspeccionada está por encima del umbral (acero inoxidable) y una salida de 0 voltios si la reflectancia de la superficie inspeccionada está por

debajo del umbral (óxido).

Así, se obtiene un sistema robusto, sensor + amplificador, capaz de tomar 12.500 muestras de  $50 \mu m$  en 1 segundo.

### **3.4.2.2. Comparación de esta técnica frente al proceso de imagen**

Esta técnica presenta ventajas e inconvenientes que detallamos en este apartado.

Entre las ventajas podemos citar:

- Este sistema no necesita procesado posterior a la toma de resultados, por obtenerse estos en tiempo real (el sistema cada  $80 \mu seg$  nos da una medida de reflectancia).
- La señal de salida es binaria, 12 o 0 voltios, a diferencia de un sensor de imagen de área donde cada píxel está muestreado por un valor entre 0 y 255 (escala de grises).
- Se puede realizar fácilmente mediante hardware, algoritmos sencillos para contar, almacenar y decidir en tiempo real.

Entre sus desventajas citamos:

- Un sistema de visión tiene la ventaja de obtener mucha más información que un sensor láser en la misma unidad de tiempo; una cámara puede tomar más de 1 millón de datos en cada imagen, entonces, si se toman 16 imágenes por segundo, se obtienen 16 millones de muestras frente a las 12500 que se obtienen con un sensor por segundo.
- No tiene el poder de discriminación que se puede obtener mediante el procesado de imagen. En principio no podría distinguir entre defectos que hagan bajar la reflectancia por debajo del umbral establecido.

### **3.4.2.3. Resultados obtenidos con sensor láser en laboratorio**

Se han realizado dos pruebas, obteniéndose los siguientes resultados:

- 1ª prueba. Plancha tipo B (pocas manchas de cascarilla). Área de barrido: ventana de 31 mm × 23 mm; separación entre líneas verticales: 50 $\mu$ m; velocidad de barrido: 1 m/min; contador de muestras por encima del umbral (salida 12 voltios = acero inoxidable): cont\_a = 145864 muestras; contador de muestras por debajo del umbral (salida 0 voltios = óxido): cont\_o = 11193 muestras

Estos resultados muestran que el 93% de la superficie inspeccionada es acero inoxidable y el 7% es cascarilla residual.

- 2ª prueba. Plancha tipo C (muchas manchas de cascarilla). Área de barrido: ventana de 155 mm × 25 mm; separación entre líneas verticales: 50 $\mu$ m; velocidad de barrido: 1 m/min; contador de muestras por encima del umbral (salida 12 voltios = acero inoxidable): cont\_a = 351804 muestras; contador de muestras por debajo del umbral (salida 0 voltios = óxido): cont\_o = 262522 muestras

Estos resultados muestran que el 57% de la superficie inspeccionada es acero inoxidable y el 43% está por debajo del umbral.

Estos resultados son muy diferentes entre sí y en el caso de la muestra tipo C se encuentran claramente exagerados respecto al porcentaje de óxido obtenido. Las siguientes figuras 3.29 y 3.30, muestran varias imágenes de la realización de estas pruebas:



**Figura 3.29:** El cabezal láser se montó en un centro de mecanizado, el cual barrió a una velocidad de 1 m/min dos planchas diferentes.



**Figura 3.30:** Umbral establecido en el amplificador: 850 (valores por encima de 850 dan una salida de 12 voltios => acero y valores por debajo de 850 dan una salida de 0 voltios => óxido) después de haber realizado el ajuste (así, se afina en la detección de cascarilla residual)

#### **3.4.2.4. Sistema industrial SICA I para inspección de cascarilla basado en sensores fotoeléctricos**

El sistema de inspección de cascarilla se basa en la medida directa de reflectancia superficial de la lámina de acero inoxidable, mediante sensores fotoeléctricos. Su implementación ha evolucionado a partir de la experiencia adquirida durante las distintas series experimentales realizadas en laboratorio y en condiciones reales en la fábrica de Acerinox (Los Barrios. Cádiz). La figura 3.31, muestra el entorno industrial de inspección.

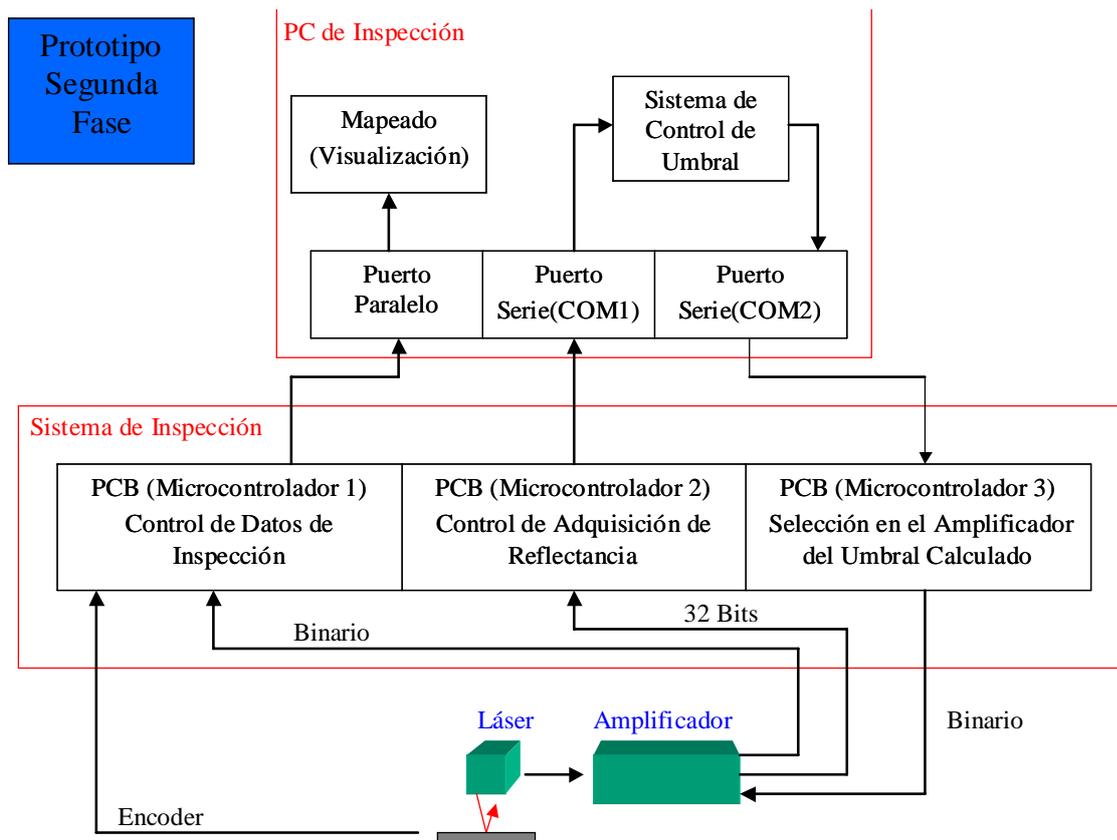
El sistema se adapta a la variación de reflectancia base de la lámina de acero inoxidable, mediante una tarjeta de umbralización dinámica. El sistema SICA I integrado actualmente en el entorno industrial se muestra en la figura 3.32, y el esquema general con la arquitectura y todos los elementos del sistema (conexiones, control de umbral, etc.) en la figura 3.33.



**Figura 3.31:** Entorno de inspección de cascarilla residual en laminados de acero inoxidable



Figura 3.32: Sistema para inspección superficial de acero inoxidable SICA I



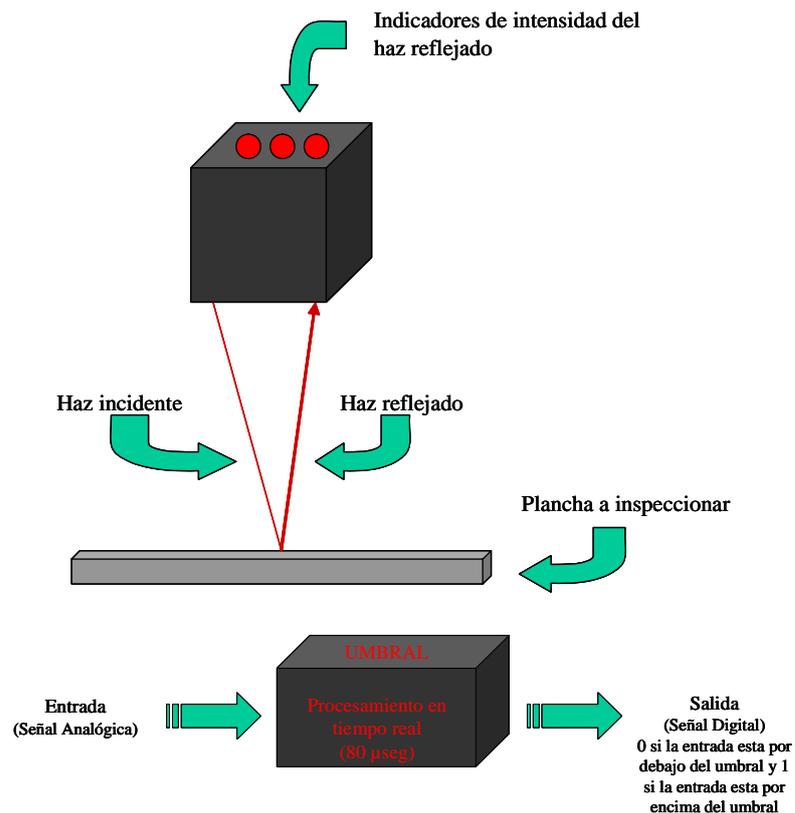
**Figura 3.33:** Esquema general del sistema para inspección superficial de acero inoxidable SICA I

Las cualidades del sistema son la eficacia de funcionamiento frente al ruido del entorno, la robustez en las mediciones realizadas por el conjunto sensor-amplificador (figura 3.34), y las comunicaciones entre sensor y PC.

El láser de diodo emite un haz colimado de  $650\text{ nm}$  de longitud de onda. La estructura irregular de la superficie inspeccionada puede originar dispersión aleatoria en la reflexión del haz. Por este motivo, el tamaño de grano de la plancha de acero inoxidable puede influir en la inspección de la superficie del material, desviando el haz reflejado por dispersión en las irregularidades debidas a la rugosidad de la superficie.

Para estudiar este posible problema se plantean dos casos en función del tamaño

de grano, el primero menor a  $50 \mu m$  y el segundo mayor o igual a  $50 \mu m$ . En el primer caso, si un haz de  $50 \mu m$  de diámetro incide sobre un grano de tamaño inferior, el efecto que produce es una integración del haz reflejado que captura el promedio de luz reflejada en la zona. Este valor promedio depende de la estructura superficial, es decir, de la naturaleza del acabado de la superficie (mate o brillante).



**Figura 3.34:** (a) Cabezal láser, (b) Amplificador

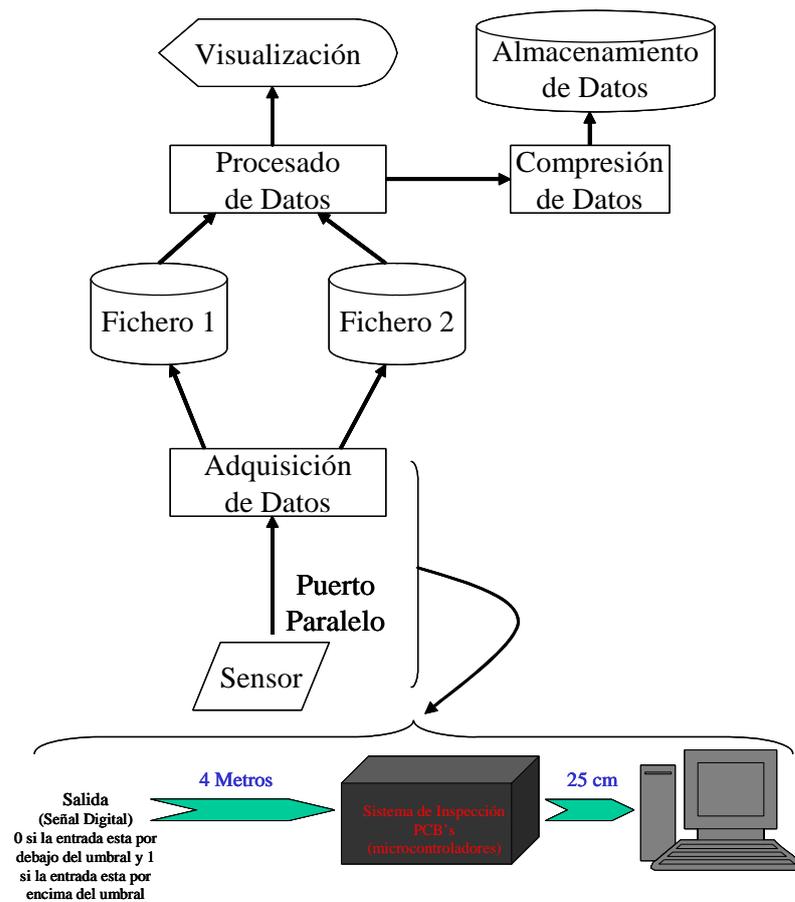
En el segundo caso, los cambios de orientación de la normal a la superficie debido al “borde de grano” pueden dar lugar a cambios de reflectancia en el sensor comparables a los inducidos por la existencia de manchas de óxido en la superficie. Por lo tanto se podrían encontrar “falsos positivos”, es decir, acero inoxidable detectado como cascarilla. Las pruebas experimentales realizadas en distintas planchas de acero inoxidable, no han mostrado influencia del “borde de grano”. Pero, es aconsejable

hacer un estudio completo con todos los tamaños de grano y rugosidades posibles, en planchas sin cascarilla. Los “falsos negativos” (contabilizar acero inoxidable cuando existe cascarilla) es más improbable. Debido a que la lente de recepción de haz, del cabezal láser, está dispuesta de tal forma que sólo recibe radiación con un cierto ángulo, en concordancia con el ángulo del haz incidente. Además, sólo puede recibir radiación de 650 *nm*. Esto protege al sensor de luz blanca exterior natural, fluorescentes, etc.

El amplificador realiza las siguientes funciones: adaptación de la señal analógica, conversión A/D, selección de modos de trabajo, visualización de datos y umbralización de la señal de reflectancia para discriminación entre el acero inoxidable y la cascarilla. Esto permite en tiempo real de la aplicación, cada 80  $\mu\text{seg}$ , inspeccionar una mancha de óxido sobre el fondo de acero inoxidable.

#### **3.4.2.5. Adquisición, visualización y reconfiguración dinámica de umbral en tiempo real**

El sistema está compuesto por dos subsistemas. El primero realiza la adquisición del resultado de inspección y se ha llevado a cabo con un microcontrolador PIC que es la interfaz entre el amplificador y el PC. En el PC hay un programa que captura los datos por el puerto paralelo. El esquema de adquisición se muestra en la figura 3.35.



**Figura 3.35:** Diagrama de bloques de la adquisición, por puerto paralelo, de los datos binarios de inspección del sensor fotoeléctrico

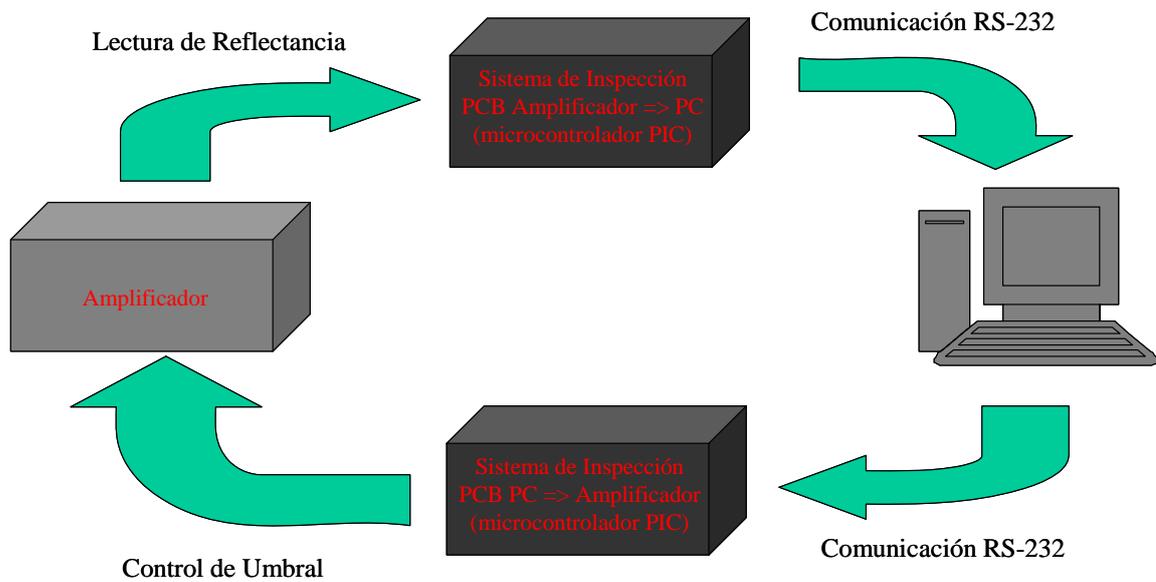
El segundo subsistema se encarga de la reconfiguración dinámica de umbral. La intensidad del haz reflejado en la plancha de acero inoxidable se muestrea en un rango de 0 a 4095. Los valores más bajos de este rango representan el defecto de cascarilla residual y los valores más altos acero inoxidable. La precisión del sensor fotoeléctrico es mayor que la de un píxel de una cámara convencional (rango de 0 a 255 niveles de intensidad).

La reflectancia de acero inoxidable base varia en función del tipo de plancha. Por este motivo es necesario ajustar de forma dinámica el umbral que distingue entre acero inoxidable y cascarilla. El amplificador puede ajustar el umbral de forma

manual frente a variaciones, pero este método es inviable en la práctica debido al requisito de funcionamiento en tiempo real de la aplicación. Para solucionar este problema, el sistema SIVA I incorpora reconfiguración dinámica de umbral en tiempo real.

La comunicación serie amplificador-PC permite adquirir la reflectancia de cada tipo de acero inoxidable y la comunicación serie PC-amplificador seleccionar automáticamente el umbral de discriminación óptimo para cada clase de acero inoxidable. Esta realimentación de umbral utiliza los dos puertos serie que posee el PC. El cálculo del nivel de discriminación entre acero inoxidable y cascarilla se realiza en el PC y se muestra al operador de línea mediante una interfaz grafica de usuario.

La primera comunicación se realiza a través de un programa en ensamblador, embebido en un microcontrolador PIC (interfaz entre amplificador y PC), que continuamente adquiere la reflectancia del amplificador y envía al PC. La tasa de transmisión es 7000 valores de reflectancia por minuto. La segunda comunicación entre PC y amplificador, también por vía RS-232, la realiza otro programa en ensamblador incorporado en otro microcontrolador PIC. El refresco de umbral se realiza cada 3 min. La siguiente figura 3.36, muestra gráficamente la realimentación.



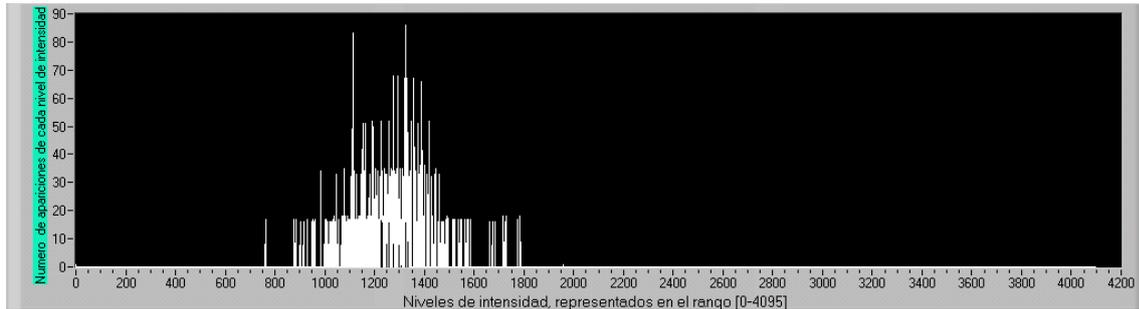
**Figura 3.36:** Esquema de realimentación para control de umbral

La interfaz gráfica de usuario, visualización y control de umbral se ha implementado mediante el entorno de programación LabView. La primera parte del programa desarrollado, captura 7000 datos en un minuto. Después calcula el histograma, lo muestra por pantalla y finalmente calcula el mínimo de reflectancia y umbral. En el caso de presencia de acero inoxidable y cascarilla en los datos de reflectancia, aparece una distribución bimodal de niveles de reflectancia. El lóbulo mayor corresponde a la base de acero inoxidable de menor absorción y el otro lóbulo de mayor absorción, al óxido o cascarilla. El umbral de discriminación es el valor mínimo de reflectancia que separa ambos lóbulos y éste varía en función de la clase de acero inoxidable. Estas tres operaciones se realizan de forma continua en un minuto de inspección.

La segunda parte del programa se encarga de calcular la media de los umbrales cada tres minutos, mandar el nuevo umbral por el puerto serie al amplificador y visualizar el nuevo umbral por pantalla.

La figura 3.37 muestra un histograma de 1 min. de inspección y la figura 3.38 varias pruebas de inspección con reconfiguración dinámica de umbral cada tres mi-

nutos.



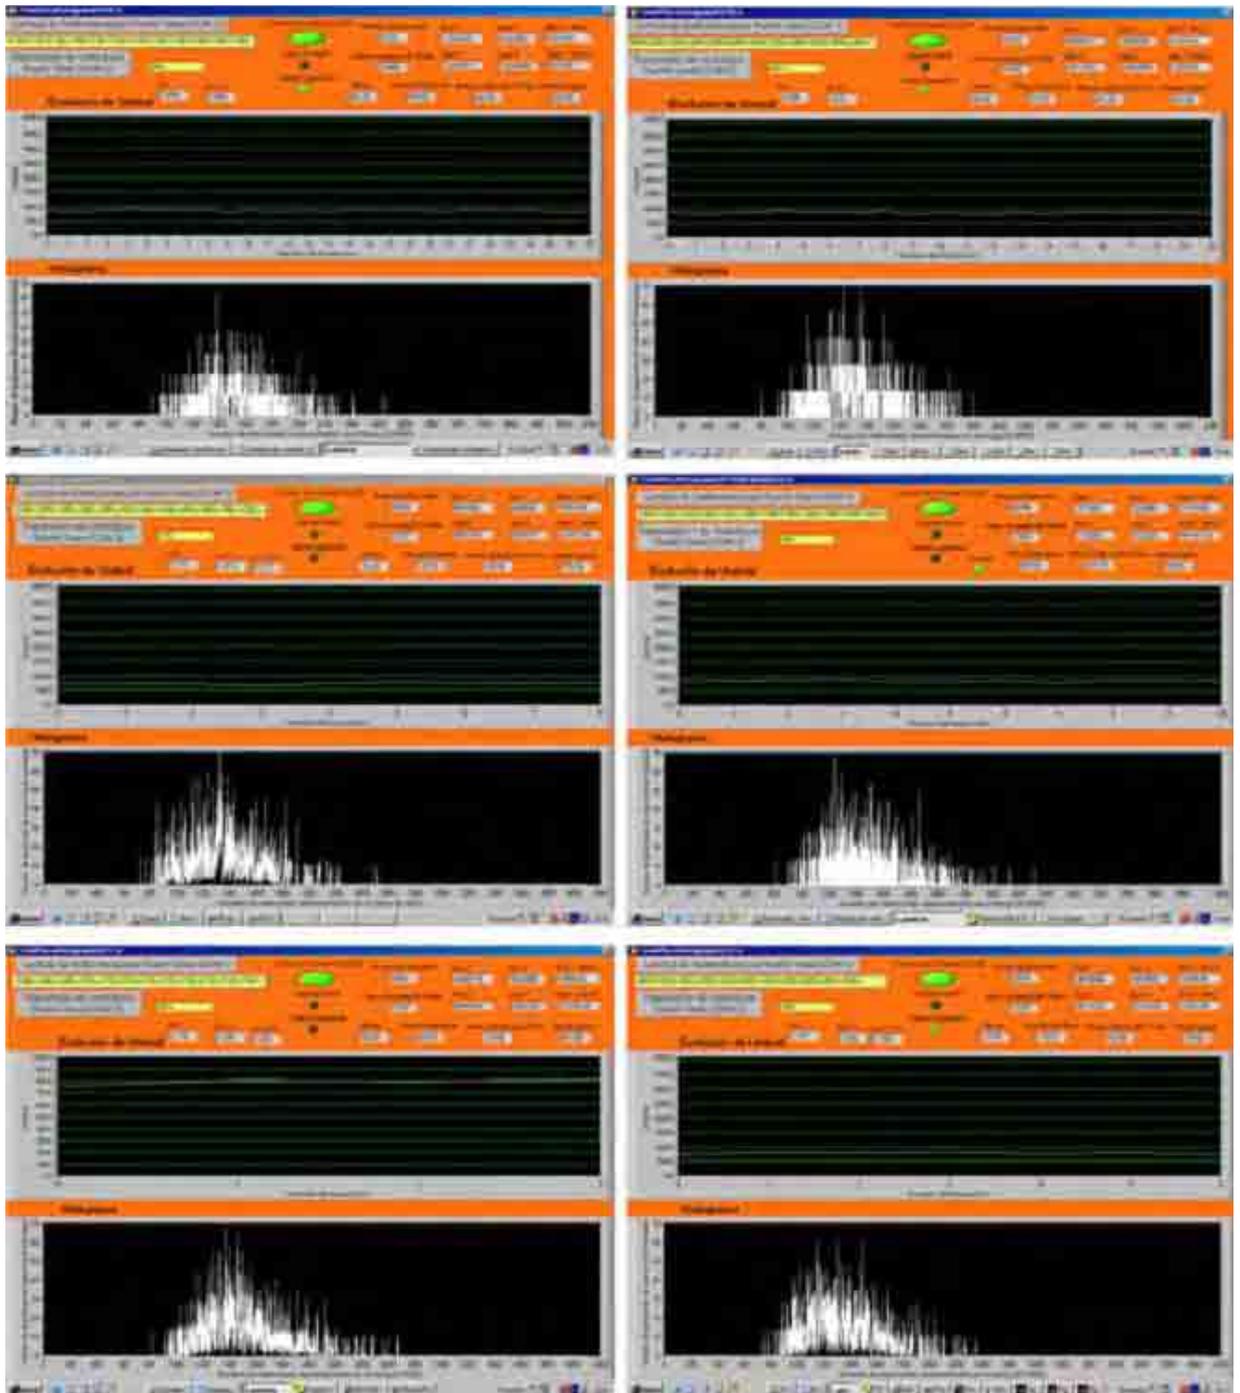
**Figura 3.37:** Histograma realizado con 7000 datos de reflectancia

En los histogramas se observa una gran variedad de niveles de intensidad. Estos corresponden a cambios de reflectancia debido a la superficie (grano natural del acero inoxidable). En la figura 3.39 se puede observar el defecto superficial (cascarilla residual) que, en este caso, posee el menor nivel de intensidad en la imagen y la gran variedad de niveles de intensidad relativos al acero inoxidable.



**Figura 3.39:** Imagen de acero inoxidable con defecto de cascarilla residual

La electrónica específica diseñada e integrada en SIVA I permite la comunicación bidireccional entre el sensor y el PC, en tiempo real. Al tratarse de electrónica propia

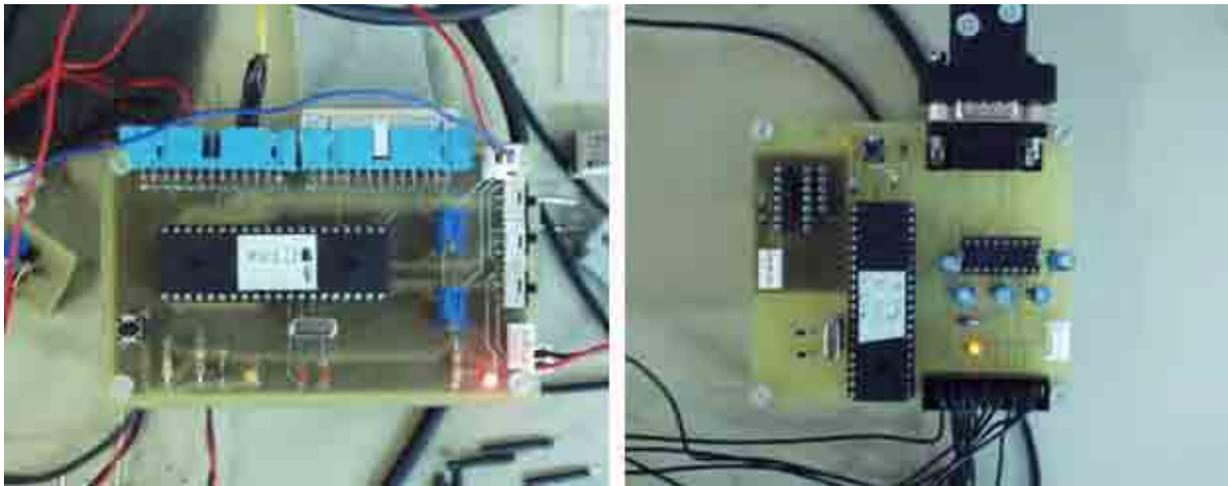


**Figura 3.38:** Interfaz de usuario que muestra el histograma cada minuto y la variación de umbral cada 3 minutos de inspección

del sistema, se pueden realizar modificaciones relativas al tratamiento de señales y se evitan las limitaciones de los diseños comerciales cerrados.

La tarjeta de circuito impreso del primer subsistema para comunicación por puerto paralelo entre el sensor fotoeléctrico y PC, garantiza la velocidad de transferencia y fiabilidad exigida por la aplicación (figura 3.40(a)). Además, el subsistema obtiene información del desplazamiento de la lámina de acero inoxidable mediante una señal de un codificador óptico incremental. Esto permite tomar datos binarios de inspección en función de la velocidad de la lámina de acero inoxidable y localizar las manchas de cascarilla residual de forma precisa.

La electrónica desarrollada para el segundo subsistema de control automático de umbral está formada por dos tarjetas (figura 3.40(b)). Una para adquisición de datos de reflectancia (amplificador→PC) y otra para selección de nuevo umbral (PC→amplificador).



**Figura 3.40:** (a) Tarjeta de adquisición por puerto paralelo, (b) Una de las tarjetas de control automático de umbral

El trabajo futuro en sistemas industriales basados en sensores fotoeléctricos engloba elementos robustos y rápidos de bajo nivel, que permitan integrar todas las funciones anteriores en una única tarjeta con microcontroladores. La adquisición de

datos que proceden del amplificador, su procesamiento y finalmente, transferencia a unidades de nivel superior de control vía RS-232, 485 o TCP/IP. Los datos relativos a los sensores fotoeléctricos llegan al PC de control en forma de paquete de información, conteniendo el tanto por ciento de cascarilla detectada, en cada fleje (figura 3.41).

El cálculo de umbral se debería realizar en el mismo módulo de lectura, mediante la implementación de algoritmos de decisión en bajo nivel. Pero, con la posibilidad de ser visualizados o modificados desde el PC por el inspector de línea.

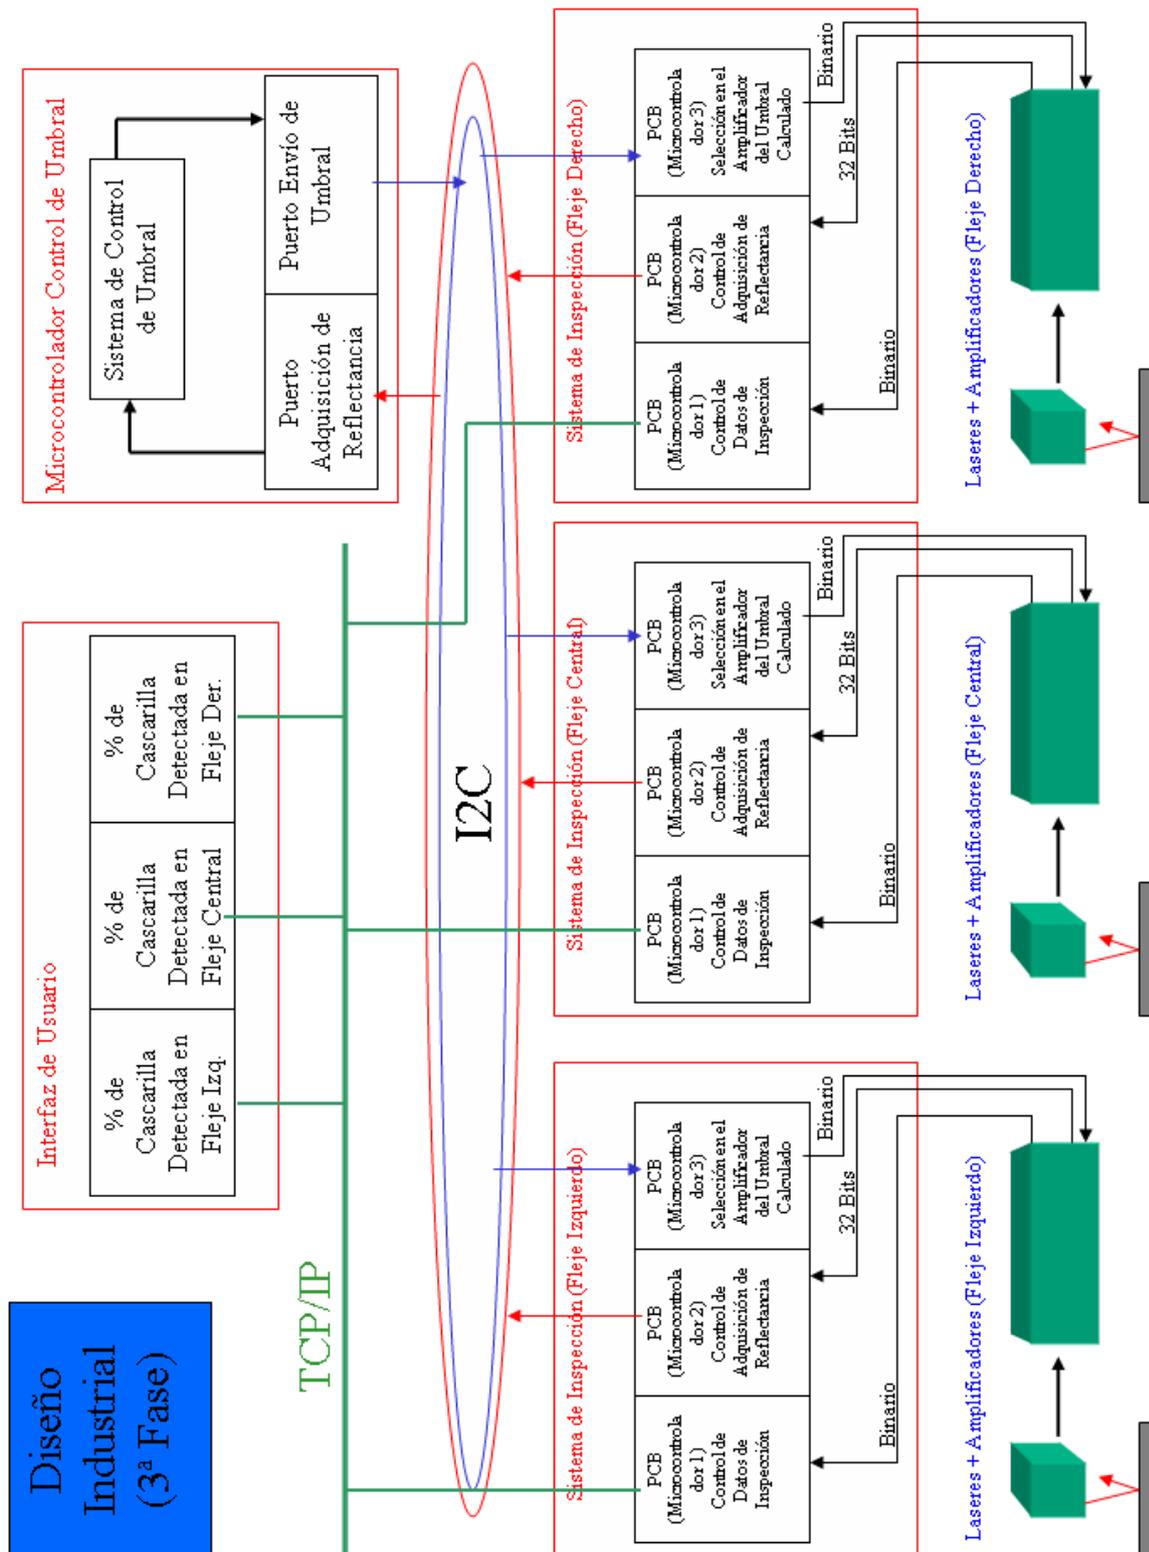
#### **3.4.2.6. Conclusiones de las pruebas de detección con sensor fotoeléctrico**

Un sistema basado en sensores fotoeléctricos es capaz de inspeccionar, en tiempo real de la aplicación, si la superficie es acero inoxidable o cascarilla mediante una señal binaria.

El sistema realiza 12500 inspecciones de 50  $\mu m$  de superficie, procesa los datos y los clasifica en un segundo; a diferencia de un sistema de visión donde la gran cantidad de datos han de ser procesados posteriormente.

Las pruebas realizadas en laboratorio y ACERINOX han mostrado la viabilidad, fiabilidad y robustez de este sistema. El umbral ajustado al defecto superficial de cascarilla residual, permite detectar la cantidad de defecto que posee la superficie inspeccionada.

Los experimentos llevados a cabo conjuntamente con el sistema de visión artificial en la línea de producción, han corroborado la correlación y complemento entre ambos sistemas en la detección de cascarilla residual.



**Figura 3.41:** Esquema general de un diseño industrial futuro para inspección con varios sensores fotoeléctricos

### **3.4.3. Detección mediante espectroscopia óptica de emisión espacio-temporal**

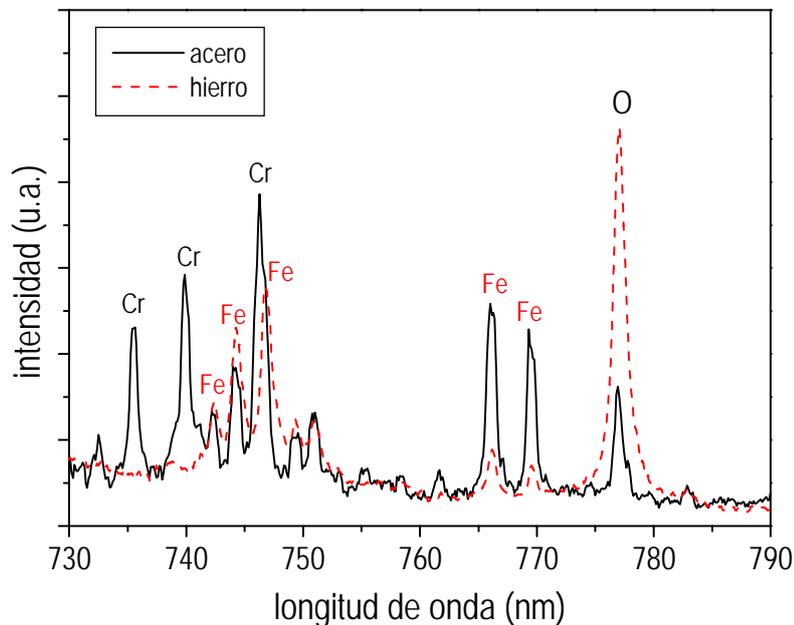
En las detecciones anteriores se han ensayado métodos para la determinación del contenido superficial de óxido de hierro basados en la absorción diferencial de las manchas de óxido frente al fondo de acero inoxidable dentro del espectro visible. Dichos métodos no han permitido establecer zonas críticas de absorción en banda estrecha donde la discriminación fuese completa, a pesar de que la zona visible en torno al amarillo, presenta claras ventajas tanto en la diferencia de absorción óxido-acero inoxidable como en la relativa simplicidad de los sistemas a utilizar.

Sin embargo, en colaboración con el Instituto de Óptica se ha planteado la aplicación de técnicas de espectroscopia diferencial de emisión, capaces de determinar con gran sensibilidad la naturaleza de una superficie a través de la evaporación de una cantidad mínima de material ( $< 10^{-5} \text{ mm}^3$  o  $< 0.1 \mu\text{g}$ ), mediante un pulso láser de alta potencia y corta duración, y analizando simultáneamente el material evaporado por espectroscopia óptica de emisión. Con este objetivo, se han realizado diversos ensayos preliminares en el laboratorio del Instituto de Óptica del CSIC con resultados satisfactorios que a continuación se comentan.

#### **3.4.3.1. Método de detección de cascarilla residual en acero inoxidable mediante espectroscopia óptica de emisión resuelta en tiempo y espacio**

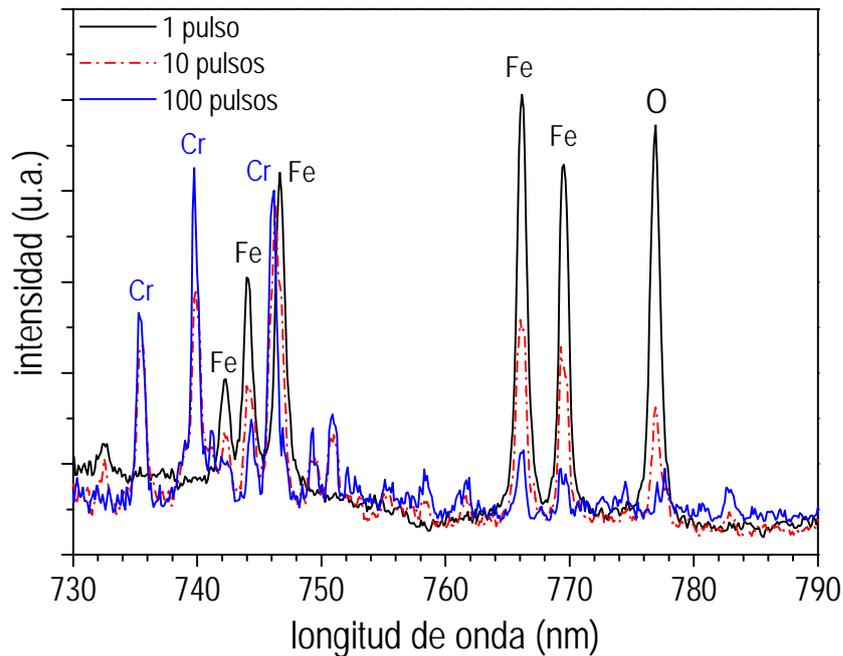
El sistema experimental utilizado está formado por un láser de UV que emite pulsos de nanosegundos (ns) y un sistema de detección compuesto por: sistema de formación de imágenes, espectrógrafo y cámara intensificada con tiempos de exposición de decenas de ns. Asimismo, y dado que los experimentos se desarrollaron en aire, se utilizó un sistema de purga de la superficie de la muestra con nitrógeno con el fin de evitar la señal asociada al oxígeno de la atmósfera.

En las pruebas realizadas se han utilizado dos tipos de muestras: acero inoxidable de tipo D con manchas (negras) de cascarilla residual que no se aprecian a simple vista ( $\sim 20 - 50 \mu m$ ) y hierro oxidado.



**Figura 3.42:** Comparación de los espectros de emisión de la muestra de acero inoxidable con cascarilla residual (tipo D) y de hierro oxidado

Inicialmente se ha analizado la sensibilidad de la técnica propuesta para la detección de oxígeno procedente del oxido de hierro. Para ello se han comparado los espectros de emisión de hierro oxidado y acero inoxidable tipo D. Los resultados obtenidos (figura 3.42) demuestran que existe un intervalo espectral adecuado (730-790 nm) en el que las líneas dominantes del espectro del acero inoxidable corresponden a cromo (Cr), hierro (Fe) y al oxígeno (O) presente en la cascarilla residual y que por tanto, el método propuesto es sensible a la presencia de hierro oxidado en la superficie del acero inoxidable.



**Figura 3.43:** Espectros de emisión de la muestra de acero inoxidable con cascarilla residual (tipo D) obtenidos bajo irradiación con 1, 10 y 100 pulsos láser

En segundo lugar, se ha estudiado la evolución de los espectros obtenidos después de irradiar 1, 10 y 100 veces el blanco de acero inoxidable con cascarilla residual, con el fin de estudiar la evolución de la composición de la capa superficial de acero inoxidable tras irradiaciones sucesivas. Los espectros obtenidos se muestran en la figura 3.43. Se observa como la intensidad de las líneas de emisión de Fe y O **disminuye** de forma significativa, mientras que la intensidad de las líneas de emisión de Cr **aumenta** tras irradiaciones sucesivas con el láser. Dicho comportamiento puede entenderse si tenemos en cuenta cuál es el efecto de las irradiaciones sucesivas sobre la superficie del acero inoxidable:

- El primer pulso incide sobre un área en la que la cascarilla residual compuesta por óxido de hierro tiene una presencia elevada. Su evaporación hace que las líneas de emisión dominantes pertenezcan a Fe y O.

- La irradiación sucesiva con el láser provoca la eliminación progresiva de la cascarilla residual superficial. Así, tras 10 pulsos se observa disminución de la intensidad de las líneas de emisión de Fe y O y un aumento de la intensidad de las líneas de emisión de Cr, asociada a que, al desaparecer la capa superficial de óxido de hierro, la zona irradiada presenta un mayor contenido de Cr superficial.
- Finalmente, después de 100 pulsos de irradiación láser, la cascarilla residual ha desaparecido casi totalmente de la superficie del acero inoxidable y la zona irradiada está compuesta mayoritariamente por Cr, por lo que la intensidad de las líneas correspondientes a dicho elemento aumentan considerablemente.

### **3.5. Conclusiones de los sistemas de detección de cascarilla**

Se ha estudiado la metodología básica de detección de cascarilla residual basada, principalmente, en la diferencia de reflectancia entre el acero inoxidable y óxido de hierro, su principal constituyente.

El método más completo es el basado en procesado de imagen. Se ha estudiado y determinado el procedimiento de detección y realizado una primera verificación con planchas de muestra de distintos tipos de calidad, que han dado resultados positivos. También se han estudiado, desde el punto de vista teórico, los aspectos dinámicos del análisis de la plancha de acero inoxidable en movimiento así como la resolución e iluminación necesarias para una detección de manchas de hasta 0,05 mm.

Uno de los métodos alternativos al de visión por computador, consiste en la utilización de un sensor fotoeléctrico excitado por láser, que tiene una superficie de exploración de 50  $\mu\text{m}$  y da una salida binaria '0' o '1' según sea la reflectancia de la superficie inspeccionada.

Se expone a continuación, brevemente, las conclusiones de cada estudio.

a) Procesado de imagen con sistema de inspección convencional.

La detección de cascarilla residual en la línea de producción de Acerinox es viable, mediante un sistema de inspección visual con adquisición y procesado de imágenes en tiempo real.

Los algoritmos de procesamiento empleados son capaces de detectar correctamente los defectos de cascarilla residual, sin confundirlas con otros defectos presentes en las muestras.

A continuación se resume el conocimiento del dominio adquirido a partir de la detección de defectos superficiales de cascarilla residual mediante un sistema convencional y que posteriormente se utilizará como conocimiento del dominio de inspección de superficies en la arquitectura ARDIS:

- *Resolución.* La cota mínima en el tamaño de las manchas a detectar ( $50 \mu m$ ) y la conveniencia de que dicha mancha mínima contenga al menos  $2 \times 2$  píxeles para hacer suficientemente robusta su detección por parte de los algoritmos de procesamiento, hace necesaria una resolución en el plano del objeto (lámina de acero inoxidable) de al menos  $40 \frac{\text{píxeles}}{\text{mm}}$ , es decir, el píxel deberá tener un tamaño máximo en el acero inoxidable de  $25 \mu m$ .
- *Tiempo de Exposición.* El movimiento de la plancha de acero inoxidable en el tren de laminación, a una velocidad máxima de  $1 \frac{m}{seg}$ , obliga a utilizar tiempos de exposición suficientemente pequeños para evitar que la imagen aparezca difuminada. Los datos de tamaño máximo del píxel en el plano objeto y de velocidad de la lámina nos llevan a unos tiempos de exposición del orden de  $25 \mu seg$ .
- *Iluminación difusa.* El granulado presente en la superficie del acero inoxidable, unido a la alta reflectancia del metal, provoca reflejos y sombras si la ilumi-

nación empleada es direccional. De esta manera, las sombras se confunden fácilmente con cascarilla. Por este motivo, se propone el uso de iluminación difusa.

- *Intensidad luminosa.* El corto tiempo de exposición necesario, unido al reducido tamaño del píxel en el plano del objeto, obligan a utilizar fuentes luminosas de alta potencia. La conveniencia de emplear iluminación difusa aumenta esta necesidad, ya que los difusores de luz, por su propia naturaleza, introducen pérdidas luminosas significativas. La posibilidad de acercarse al acero inoxidable tanto la fuente de luz como la cámara para aumentar la cantidad de luz disponible se ve limitada por consideraciones de seguridad del equipamiento ante eventuales problemas en el tren de laminación. La necesidad de alta potencia luminosa, junto a la brevedad de los tiempos de exposición, conducen por ejemplo, a la utilización de una fuente de luz pulsante de alta potencia.
- *Óptica.* La utilización de un factor de magnificación relativamente pequeño (0,4 tomando un tamaño habitual de píxel en el plano de la imagen de  $10\mu m$ ), la conveniencia de situar la cámara relativamente cerca del acero inoxidable para aprovechar la energía luminosa, así como la conveniencia de utilizar una apertura elevada por el mismo motivo, llevan a profundidades de campo reducidas. La existencia de posibles ondulaciones en la lámina de acero inoxidable, y en cualquier caso las fluctuaciones en el grosor de la lámina (de varios mm), podrían requerir ajustes de la distancia de enfoque durante el proceso de inspección. Estos factores llevan a una cuidadosa elección de la óptica a emplear, y posiblemente, al empleo de un objetivo motorizado controlable por el algoritmo de procesamiento.

Así pues, un procedimiento de detección basado en este método necesita una cámara de alta resolución. Por otro lado, la velocidad de análisis de imagen depende del cálculo a efectuar y de la potencia del procesador.

Los aspectos concretos de iluminación son: posición de la cámara, número de cámaras y movimiento necesario para aumentar la superficie a explorar, etc.

La salida de la cámara va a un equipo de proceso formado por un PC industrial y una tarjeta de adquisición de imágenes (“frame grabber”), que está situado en la cabina de inspección. Este equipo realiza el procesado de imagen y dispone de una interfaz de usuario para control de la cámara y visualización de los resultados de inspección.

b) Inspección con sensores fotoeléctricos excitados por láser.

Método alternativo que utiliza sensores fotoeléctricos excitados por láser. Este sistema es capaz de evaluar si la superficie inspeccionada es acero inoxidable o cascarilla residual, con una señal binaria (12 voltios = acero inoxidable; 0 voltios = óxido). En este procedimiento es crítica la caracterización del umbral de detección.

A continuación, se exponen brevemente las conclusiones:

- Las pruebas preliminares mostradas, indican que, estableciendo un umbral lo más ajustado posible a una mancha de óxido, se consigue tener una valoración directa de la cantidad de cascarilla que posee la superficie inspeccionada.
- El pequeño porcentaje de área inspeccionada debido a la pequeña superficie de exploración ( $50 \mu m$ , cada  $80 \mu seg$ ) es suficiente para obtener un valor representativo de una unidad mínima superficial que en los procedimientos de inspección de Acerinox suele ser del orden del ancho\_fleje  $\times$  metro\_longitudinal.
- El sistema de movimiento transversal para cubrir un cierto fleje y el número de sensores por fleje aumentan la superficie a explorar.
- Un sistema de inspección mediante sensor fotoeléctrico láser proporciona una solución robusta al problema de detección de cascarilla residual y es más sencillo que un sistema basado en procesado de imagen.

c) Espectroscopia óptica de emisión espacio-temporal.

Del análisis de los ensayos realizados podemos extraer las conclusiones que se presentan a continuación:

- La técnica es extraordinariamente sensible a la presencia de óxido de hierro en la superficie del acero inoxidable.
- El método de inspección tiene una gran resolución espacial, pudiéndose detectar manchas de óxido (cascarilla residual) de aproximadamente  $20 \mu m$  o tamaños menores.
- El método permite, además de la detección selectiva de óxido, el reconocimiento en tiempo real de otros componentes de la superficie de la lámina de acero inoxidable.
- El presente método puede combinarse con un tren de pulsos láser para eliminar el óxido de hierro superficial, implementando un sistema de inspección y limpieza en una única técnica.

## Parte II

# Arquitectura ARDIS y entorno-aplicación SIVA II para Inspección de Superficies



## Capítulo 4

# Diseño de un sistema óptico para inspección visual de superficies basado en iluminación láser

La adquisición óptima de una imagen en inspección de superficies a alta velocidad depende de la iluminación utilizada. Por ejemplo, en el caso particular de inspección de microdefectos en superficies de acero inoxidable, es necesario iluminar apropiadamente para eliminar sombras en la captura de la imagen debido a la superficie rugosa del acero inoxidable, y también, para adquirir una imagen óptima con un corto tiempo de exposición. Así pues, en este capítulo se desarrolla un nuevo sistema óptico basado en iluminación láser, que forma parte del entorno-aplicación SIVA II para inspección de superficies.

Los sistemas convencionales de inspección se basan en iluminación visible, proporcionada por tubos fluorescentes, lámparas incandescentes, fibra óptica, etc. Además, si se necesita iluminar una superficie rugosa y brillante se utiliza un difusor. Un sistema difusor de luz utiliza una fuente de luz visible estándar y varios elementos que hacen incidir la luz en la superficie de forma irregular. Por otro lado, las desventajas de los sistemas convencionales de iluminación son corta duración, extrema

sensibilidad y elevado coste.

En este capítulo se presenta un nuevo sistema de iluminación difusa basado en una fuente láser puntual de elevada intensidad luminosa, que consigue iluminar eficazmente una pequeña superficie a inspeccionar para capturar imágenes con corto tiempo de exposición. El sistema de iluminación láser satisface las restricciones de tiempo de exposición calculado en el apartado anterior para inspección a alta velocidad de microdefectos de cascarilla residual en una plancha de acero inoxidable.

Para demostrar su funcionamiento se ha desarrollado un banco óptico de pruebas, donde se han integrado los siguientes elementos: un láser de diodo de bajo coste, un difusor, varias lentes y una cámara (sin óptica) para captura de imagen. Esto permite investigar distintas disposiciones de las lentes, difusor y cámara para lograr una imagen óptima de la superficie a inspeccionar. En concreto, se implementan en el banco óptico dos arquitecturas de formación de imagen: la primera basada en iluminación coaxial con disposición de los elementos en forma de “T” y la segunda se basa en iluminación a  $45^\circ$  con disposición en forma de “V”.

El nuevo sistema de inspección diseñado inicialmente para inspeccionar acero inoxidable, también se puede utilizar para inspeccionar otras superficies de materiales característicos de producción en línea (madera, papel, plástico, tela, etc.).

## **4.1. Iluminación basada en diodo láser. Introducción**

La iluminación utilizada en los experimentos la proporciona un láser de diodo de bajo coste. Inicialmente, este tipo de iluminación no se suele utilizar en visión artificial para iluminar una superficie, pero solucionando varios problemas se convierte en una fuente de luz robusta e ideal para su integración en un entorno industrial, por su coste y durabilidad en comparación con sistemas de iluminación convencionales. Por otro lado, en inspección de defectos superficiales micrométricos o milimétricos,

por ejemplo, defectos de cascarilla superficial en acero inoxidable, es ideal porque sólo es necesario iluminar una pequeña región entorno a  $[10-100] \text{ mm}^2$ . Por lo tanto este tipo de iluminación se puede utilizar para iluminar pequeñas regiones a inspeccionar, pero no es apropiada para iluminar grandes regiones, por ejemplo, una naranja en inspección de calidad de frutas.

El láser es una fuente de luz monocromática y el haz que genera es extremadamente coherente con una fase bien definida. Pero, la iluminación láser directa en visión artificial puede presentar problemas debido a la coherencia del haz (fenómenos de interferencia). Este fenómeno se produce al pasar un haz láser a través de una lente convergente (necesario para abrir el haz) y reflejarse el haz en la superficie a inspeccionar. Entonces, las imágenes capturas por la cámara aparecen con un patrón de puntos brillantes y oscuros, característico de la superficie inspeccionada. Cada material tiene un patrón de interferencia característico y cambia en función de la dirección de observación. Los puntos brillantes y oscuros están distribuidos de forma aleatoria en el espacio, producidos por efectos de interferencia constructiva o destructiva. Este fenómeno complica la iluminación homogénea de la superficie a inspeccionar mediante luz láser [Jahne et al., 1999].

Para solucionar este problema se ha probado un método de dispersión del haz láser, con el objetivo de conseguir iluminación láser difusa y solucionar el problema de interferencia. Éste consiste en abrir el haz láser mediante una lente convergente y posteriormente utilizar un difusor para generar un haz difuso que elimina el patrón de interferencia, denominado “speckle”.

El láser es un haz de luz colimado muy estrecho, donde el flujo de energía es unidireccional, de modo que cada rayo del haz puede considerarse paralelo a cualquier otro. Con el objetivo de aumentar el ancho del haz colimado, a la salida del haz se coloca una lente convergente. La distancia entre el láser y la lente es la distancia focal de la lente.

Por otro lado, para conseguir iluminación difusa hay que transformar los rayos

colimados procedentes de la lente convergente en rayos difusos que iluminen la superficie a inspeccionar. Para lograr esto se han utilizado difusores de vidrio estáticos y giratorios. Los mejores resultados se han obtenido con difusores giratorios, debido a que producen una iluminación difusa óptima, que elimina correctamente el ruido “speckle”.

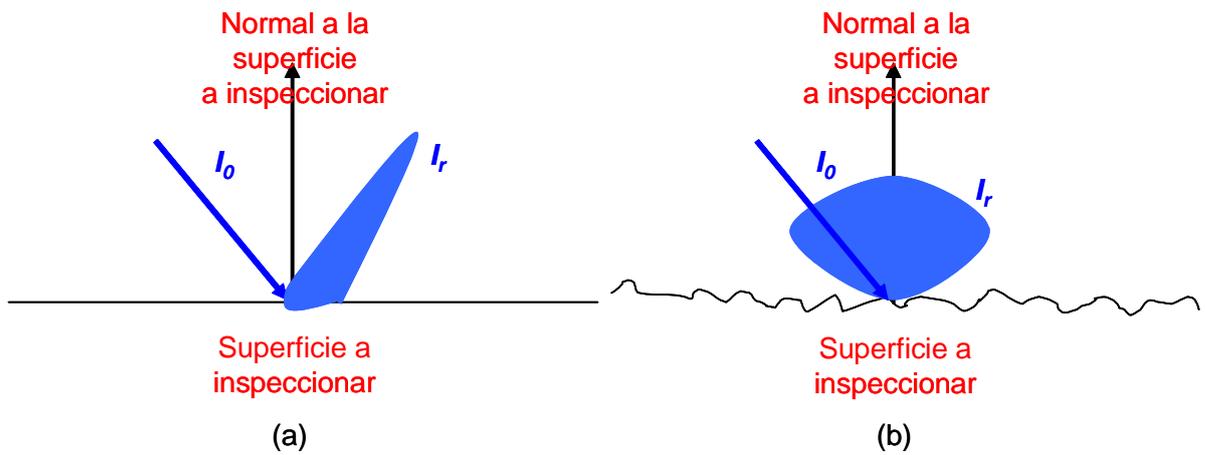
En resumen, este método de iluminación láser ilumina fuertemente una pequeña superficie a inspeccionar y permite detectar microdefectos a alta velocidad; cumpliendo con las restricciones de tiempo-real vistas en el capítulo anterior, para el caso de inspección de cascarilla residual en laminados de acero inoxidable.

#### **4.1.1. Tipos de reflexión. Grano gordo y grano fino del acero inoxidable**

La reflexión se produce al llegar los rayos de luz procedentes del difusor a la superficie a inspeccionar. Estos haces como no pueden continuar propagándose en la superficie, salen desviados en otra dirección, es decir, se reflejan. Este fenómeno depende del tipo de superficie sobre la que inciden los haces y ángulo que forman sobre la misma.

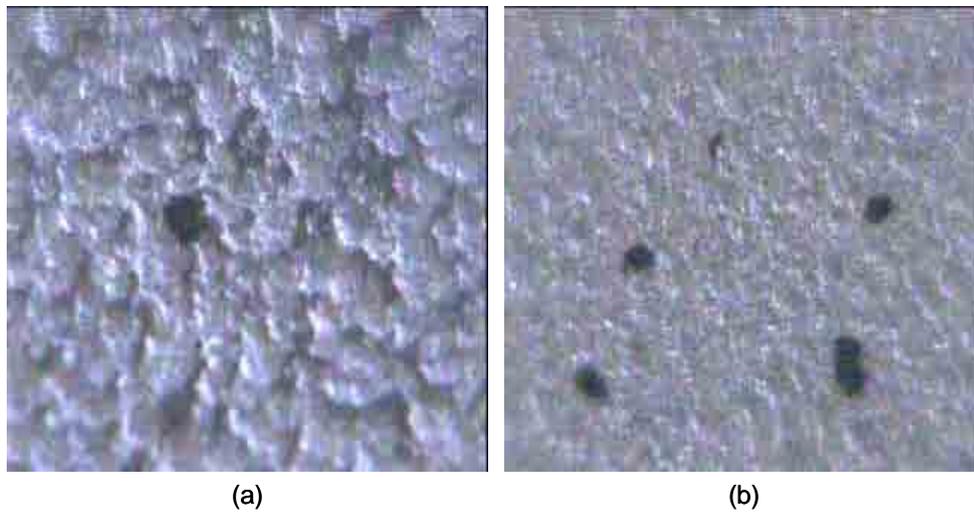
Las superficies pulidas reflejan de forma regular la mayor parte de los haces y producen un rayo de luz reflejado altamente direccional. Estos haces reflejados se observan como un pequeño cono de luz emergiendo de la superficie inspeccionada. El nombre asignado a este fenómeno es reflexión especular y se puede observar en la figura 4.1a.

Mientras que las superficies rugosas (e.j.: acero inoxidable) actúan como si estuvieran formadas por infinidad de pequeñas superficies dispuestas irregularmente y con distinta orientación, por lo que las direcciones de los haces reflejados son distintas y en cualquier dirección. Este otro fenómeno se conoce como reflexión difusa y se muestra en la figura 4.1b.



**Figura 4.1:** (a) Reflexión especular, (b) Reflexión difusa

La figura 4.2 muestra dos imágenes de acero inoxidable con cascarilla residual, las cuales reflejan la rugosidad del material. Estas superficies con distinto acabado superficial producen reflexión difusa al ser iluminadas con un haz láser difuso.



**Figura 4.2:** (a) Plancha de acero tipo B. Acabado superficial brillante y grano gordo. Imagen capturada con lupa electrónica, (b) Plancha de acero tipo D. Acabado superficial mate y grano fino. Imagen capturada con lupa electrónica

### 4.1.2. Características de los láseres utilizados

En los experimentos se han utilizado dos láseres, uno de diodo con longitud de onda en el rojo y otro de estado sólido bombeado por diodo con longitud de onda en el verde, para la iluminación de la superficie a inspeccionar. En el caso de detección de defectos de cascarilla residual en una plancha de acero inoxidable se han utilizado los dos láseres y en caso de inspección de defectos en madera sólo se ha utilizado el láser verde. Por otro lado, las aplicaciones más típicas del diodo láser son: posicionamiento, alineamiento, medida, lectura de códigos de barras, seguridad, detección de bordes, localización de tareas, testeo de fibra óptica, etc. Pero en este caso, se utiliza como fuente de iluminación de la superficie a inspeccionar.

El láser rojo es un diodo láser de la marca “Melles Griot” (figura 4.3a). El diodo es de alta calidad, diseño robusto, especialmente adecuado para aplicaciones industriales y de bajo coste. Las especificaciones técnicas son las siguientes:

- El láser emite un haz monocromático de longitud de onda  $670 \pm 10$  nm.
- El haz de salida es elíptico.
- La potencia de salida es 3 mW.
- El tamaño del haz es  $4 \times 2$  mm.
- El tamaño mínimo de “spot” o punto es  $100 \mu\text{m}$ .
- La divergencia del haz es 0,5 mrad.
- Voltaje de funcionamiento 3 – 6 V.
- Corriente de funcionamiento: 55 mA.
- Temperatura de funcionamiento:  $-10 \Leftrightarrow +50$  °C.

Por otro lado, el láser verde es un modulo compacto de alta luminosidad (figura 4.3b). Los láseres de estado sólido DPSS (“Diode pumped solid state”) son láseres de estado sólido bombeados con un láser de diodo. El láser DPSS más común, es el láser verde de longitud de onda 532 nm. Un potente diodo láser infrarrojo (superior a 200 milivatios) de longitud de onda 808 nm, bombea un cristal de Nd:YVO4 que

produce un haz de 1064 nm. Entonces, doblando la frecuencia mediante un proceso óptico no lineal en un cristal KTP se consigue un haz de 532 nm. Los láseres DPSS son compactos y eficaces en comparación con otros tipos.

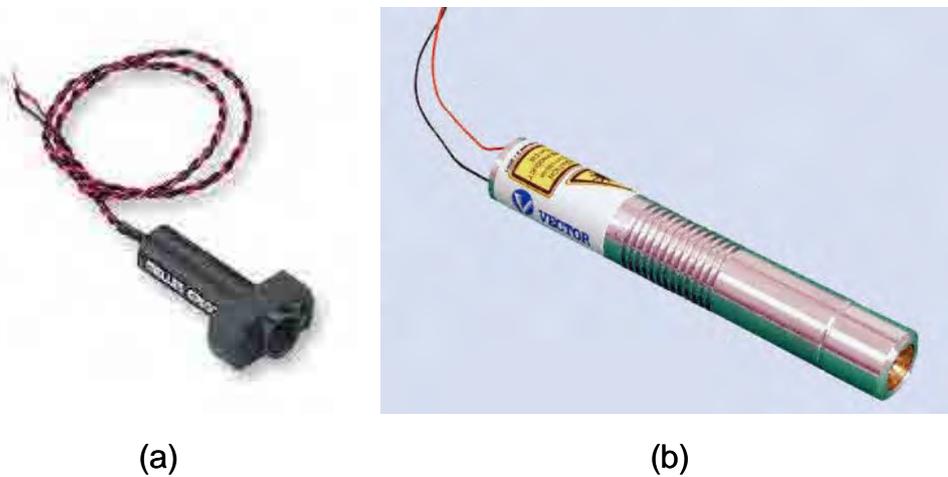
Las características más importantes son las siguientes:

- Alta luminosidad.
- Haz circular de alta calidad.
- Buen contraste con cualquier fondo de color.
- 30 veces más brillante que un láser rojo de 675nm.
- Capaz de operar a largas distancias.
- Láser DPSS (Diode pumped solid state) compacto con alta eficiencia luminosa.
- Longitud de onda más corta que un láser de diodo normal (verde, 532 nm), ideal para detección de defectos de cascarilla residual en planchas de acero inoxidable.
- Potencia de salida:  $2 \text{ mW} \pm 20\%$  (Clase 3R).
- Tensión de alimentación: 3,3 a 6 V.
- Intensidad de funcionamiento: 300 mA.
- Temperatura de funcionamiento: 15 – 35 °C.
- Longitud de onda: 532 nm (haz de color verde).
- Divergencia del haz:  $\pm 0,1 \text{ mrad}$ .
- Tamaño de haz: 3 mm.

Desde el punto de vista de inspección de superficies, el láser verde presenta algunas ventajas frente al láser rojo. La primera es la distancia a la que es capaz de iluminar la superficie a inspeccionar, que es superior a la del láser rojo. Esta característica permite inspeccionar defectos en superficies a distancias de seguridad apropiadas (por ejemplo, para inspección de cascarilla residual en acero inoxidable es necesario una distancia de seguridad mínima de 300 mm, entre la plancha de acero inoxidable y la cámara). Otra ventaja es la longitud de onda en el verde que favorece la detección del defecto de cascarilla residual en el caso de inspección en acero inoxidable (como se vio en el capítulo anterior). Por otro lado, la divergencia

del haz es menor que en un láser de diodo rojo, pero esta característica para este caso no es importante debido a que posteriormente se abre el haz para iluminar la superficie a inspeccionar.

En un principio se pensó utilizar la tensión de alimentación de los diodos láser para aumentar o disminuir la iluminación en función de la superficie a inspeccionar. Pero, en el rango de tensiones 3-6 V no se aprecian diferencias en la capacidad de iluminación del láser. Debido a esta característica se mantiene una tensión fija de 4,5 V en todos los experimentos.



**Figura 4.3:** (a) Diodo láser rojo de la marca “Melles Griot”, (b) Diodo láser verde de la marca “Vector”

### 4.1.3. Ruido de “speckle”

Una manifestación fácilmente observable de la coherencia espacial de la luz láser es su apariencia granular al reflejarse en una superficie difusa; como es el caso de una superficie de acero inoxidable. En los experimentos realizados se utiliza un láser de diodo rojo, se expande el haz pasándolo por una lente convergente (sin utilizar difusor) y se proyecta sobre una plancha de acero inoxidable. La imagen adquirida con una cámara de la zona iluminada por el láser, aparece con regiones brillantes y

oscuras. Este fenómeno se puede observar en la figura 4.4a (plancha de acero tipo B) y 4.4b (plancha de acero tipo C). La figura 4.4a muestra una imagen de una plancha de acero inoxidable tipo B, iluminada con haz láser y abierto el haz con una lente convergente. La figura 4.4b muestra el mismo experimento pero con una plancha de acero inoxidable tipo C. Las dos imágenes muestran distintos patrones de interferencia generados por los dos distintos acabados superficiales de acero inoxidable. En este caso de iluminación láser no difusa es difícil encontrar manchas de cascarilla residual en la imagen. Las imágenes con ruido “speckle” poseen un patrón de interferencia con motas oscuras, que se confunden con manchas de cascarilla.

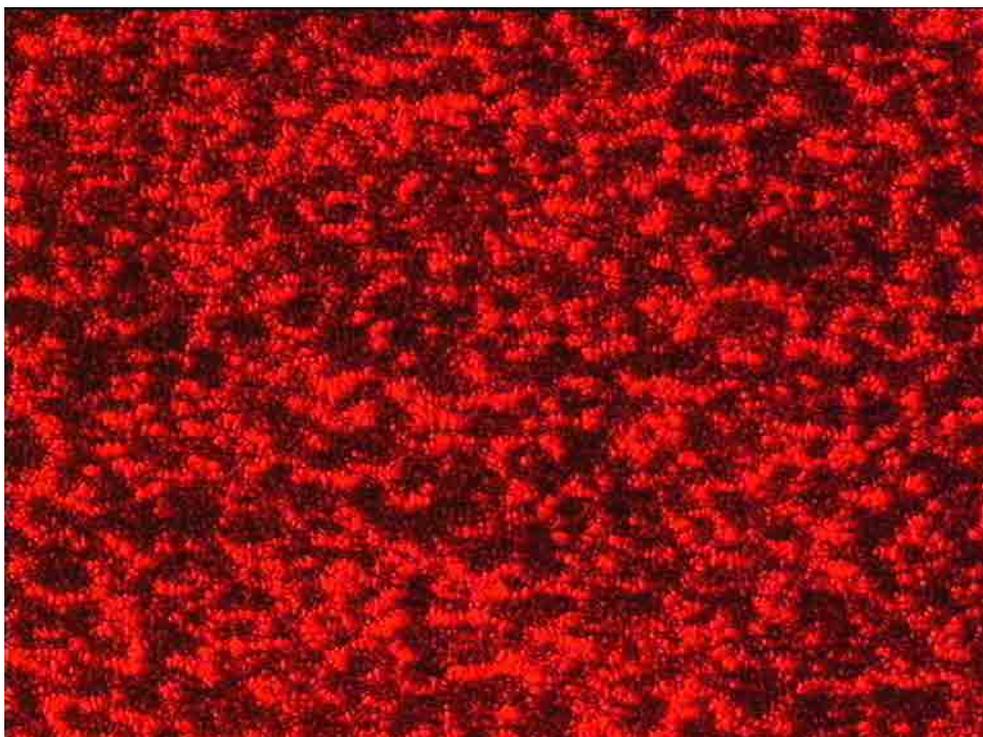
Este fenómeno se debe a la luz espacialmente coherente que se esparce en una superficie difusa. Esta luz llena la región de inspección con un patrón de interferencia estacionario. En la superficie los gránulos son extremadamente pequeños y aumentan en tamaño con la distancia. En cualquier ubicación en el espacio el campo resultante es la superposición de muchas ondas esparcidas contribuyentes. Éstas deben tener una fase relativa constante, determinada por la longitud del camino óptico de cada esparcidor al punto en cuestión, para mantener el patrón de interferencia [Hecht & Zajac, 1986].

En los apartados 4.4.1 y 4.4.2 se muestran varios experimentos donde se elimina el ruido “speckle”. Necesario para poder formar la imagen con iluminación láser y observar si existe cascarilla residual en la imagen.

En resumen, el speckle es una forma especial de luz reflejada con apariencia granular. Donde cada punto de la superficie dispersa los rayos de luz incidentes, que posteriormente interfieren entre ellos. Este fenómeno produce un patrón aleatorio de interferencia en el espacio llamado “ruido speckle” y es característico de cada tipo de superficie.



(a)



(b)

**Figura 4.4:** (a) Ruido de speckle en una plancha de acero inoxidable tipo B, (b) Ruido de speckle en una plancha de acero inoxidable tipo C

#### 4.1.3.1. Utilización del ruido “speckle”. Medición óptica de la rugosidad

En otros casos, distintos al que nos ocupa, no se elimina el ruido “speckle” y se utiliza para medir alguna característica superficial del material a inspeccionar. Por ejemplo, la rugosidad que es una medida del relieve de una superficie. La rugosidad puede medirse directamente del perfil de la superficie (registrada mediante una púa electromecánica u óptica), o puede calcularse a partir de la dispersión de la luz.

En inspección de defectos superficiales en materiales laminados, no se necesita medir la rugosidad de la superficie, pero este método que utiliza el ruido “speckle” se podría utilizar para caracterizar el tipo de superficie inspeccionada (acero inoxidable, madera, plástico, etc.). Por esta razón, se comenta brevemente este caso.

La rugosidad de la superficie se puede obtener tanto de la intensidad media dispersada como de la correlación de “speckles” [Hogert et al., 1997]. La distribución de intensidad aleatoria que se observa cuando un haz láser ilumina una superficie, es lo que se denomina “speckle” y se forma por la interferencia de ondas coherentes reflejadas en las irregularidades de la superficie.

Una medida del contraste “speckle” es el cociente:  $C = \frac{\sigma_I}{\langle I \rangle}$ ; donde  $\sigma_I$  es la desviación estándar de la intensidad e  $\langle I \rangle$  su valor medio. Otro parámetro importante es el tamaño del speckle. En un sistema óptico, el tamaño del speckle viene dado por la ecuación:

$$\Delta s \approx \frac{1,22\lambda z}{D}$$

donde  $\lambda$  es la longitud de onda del láser utilizado en el experimento,  $z$  es la distancia entre la lente y el plano imagen, y  $D$  el diámetro de la lente o si es un sistema de lentes el diámetro de la pupila de salida. Un sistema óptico típico genera un speckle que oscila entre 1 y 24  $\mu m$ .

Los métodos ópticos que utilizan el “speckle” para medir la rugosidad de una superficie son los siguientes:

- Método de contraste de “speckle” en el plano imagen. Es un método básico

para evaluar las propiedades de una superficie rugosa mediante “speckle” en el plano imagen. Usa un láser He-Ne que ilumina una superficie rugosa colocada en un dispositivo con movimiento x-y (escáner x-y). El sistema óptico consiste en un objetivo y un disco rotante con varios diafragmas. Cambiando los diafragmas se logra variar el tamaño del “speckle”, con el objetivo de conseguir el máximo contraste.

- Método de contraste de “speckle” en el plano de difracción. En este método se emplea un rugosímetro láser que utiliza el contraste de “speckle” en el plano de difracción. El contraste de “speckle” producido por la superficie rugosa es detectado por un fotodetector, para estudiar la relación de su contraste con la rugosidad y el tamaño de la zona iluminada.
- Método de “speckle” policromático. En este método se estudia el “speckle” producido por luz policromática. En este caso, si la coherencia temporal de la luz incidente es comparable a la rugosidad, el contraste de “speckle” será muy bajo.
- Método por correlación de “speckles”. La correlación entre dos “speckles” producidos por la misma superficie, en condiciones diferentes, tiene información sobre la rugosidad y otras características de la superficie.

## 4.2. Lentes

La primera fase de un sistema de visión industrial por computador es la adquisición de la imagen. Normalmente, se ilumina la superficie a inspeccionar con luz natural o artificial en el visible y se forma la imagen con las lentes de una cámara digital. Estos sistemas clásicos, en algunas aplicaciones de inspección superficial, no forman una imagen adecuada debido a la calidad del sistema óptico. Esto se debe al elevado coste que supone inspeccionar una superficie con varias cámaras y ópticas adecuadas. Por tanto, estos sistemas incrementan el esfuerzo en el preprocesado

de la imagen para mejorar la calidad. En visión industrial por computador es más eficiente obtener una buena imagen inicial que mejorar la imagen con preprocesado, debido a la extensa superficie que es necesario inspeccionar. En el caso de defectos de cascarilla residual en planchas de acero inoxidable, al tratarse de manchas de óxido muy pequeñas, una incorrecta formación de la imagen no muestra los defectos; y mediante preprocesado posterior de la imagen tampoco se consigue detectarlos.

Así pues, en un sistema de visión industrial por computador para inspección de superficies es crucial adquirir bien la imagen para no perder u ocultar información. La degradación de una imagen causada por una incorrecta adquisición puede complicar el preprocesado de la imagen o incluso puede ser imposible de corregir.

El sistema de inspección de superficies basado en iluminación láser desarrollado en esta tesis permite adquirir imágenes óptimas de diferentes superficies. El sistema mejora la calidad de las imágenes estándar, de tal forma que, el procesado posterior de la imagen en el computador sea sencillo y rápido.

En los experimentos se utiliza una sola lente simple de alta calidad para formar una buena imagen. La simplificación de la óptica se realiza debido a que la distancia entre la lente y la superficie a inspeccionar es fija. Esto permite ahorrar costes en un sistema de inspección industrial y facilita la integración de un conjunto alineado de sensores de imagen.

#### 4.2.1. Lente plano-convexa

Las lentes plano convexas tienen una superficie plana y otra convexa. La distancia focal es positiva. Éstas se utilizan en muchos dispositivos: telescopios, colimadores, magnificadores, radiómetros, “transceivers” ópticos y condensadores ópticos [Optics-Guide, 1999]. Las características de este tipo de lentes son las siguientes: se usan para converger la luz incidente y pueden formar imágenes reales.

Las lentes de cristal utilizadas presentan excelentes propiedades de transmisión

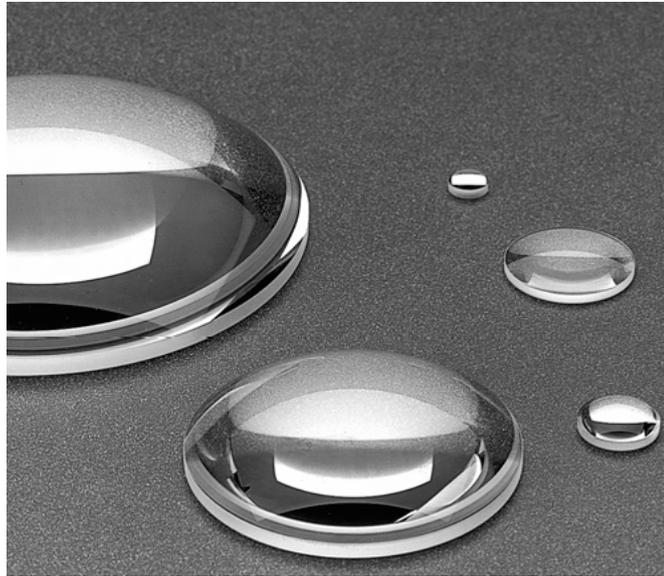
de radiación desde 400nm hasta  $1 \mu m$ . En los experimentos se han utilizado varias lentes plano-convexas con distintas especificaciones:

- Lente plano-convexa de 55 mm de distancia focal
  - Diámetro (d): 10 mm.
  - Tipo de vidrio: BK7.
  - Índice de refracción (n): 1,5187.
  - Número F (F/#): 5,5.
  
- Lente plano-convexa de 160 mm de distancia focal
  - Diámetro (d): 10 mm.
  - Tipo de vidrio: BK7.
  - Índice de refracción (n): 1,5187.
  - Número F (F/#): 16.

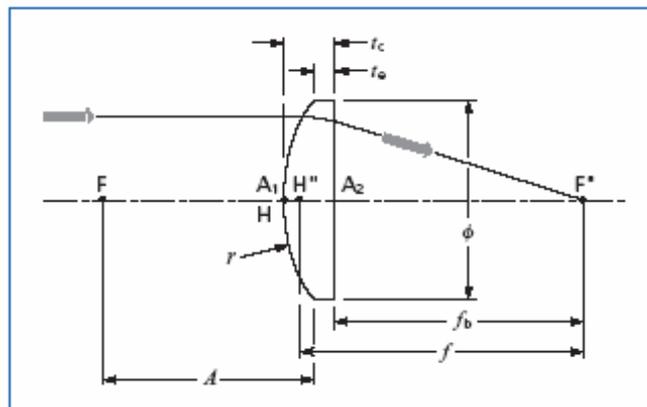
La figura 4.5a muestra varias lentes plano-convexas de distintos diámetros de Melles Griot y la 4.5b el diagrama de trazado de rayos.

### 4.2.2. Óptica para adquisición de imagen

La imagen se forma utilizando una lente simple. El objetivo es minimizar el sistema óptico de adquisición para reducir el coste del sistema de inspección. En los experimentos se ha formado la imagen con magnificación  $M=1$ . La distancia entre la lente y la plancha de acero a inspeccionar es el doble de la distancia focal de la lente, y la distancia entre la lente y el plano imagen, igualmente, el doble de la distancia focal. Con esta configuración se consigue inspeccionar defectos del tamaño físico del píxel de la cámara ( $\sim 10 \mu m$ ). Por ejemplo, en el caso de inspección de cascarilla residual, se pueden inspeccionar fácilmente y de forma viable en la industria de acero inoxidable, defectos mínimos de hasta  $20 \mu m$  (en este caso mínimo, el defecto de  $20 \mu m$  ocupará 2 píxeles en la imagen adquirida; teniendo en cuenta la restricción vista en el capítulo anterior de mínimo dos píxeles por defecto superficial).



(a)



(b)

**Figura 4.5:** (a) Lentes plano convexas de Melles Griot, (b) Diagrama de trazado de rayos en una lente plano-convexa (Simbología de Melles Griot)

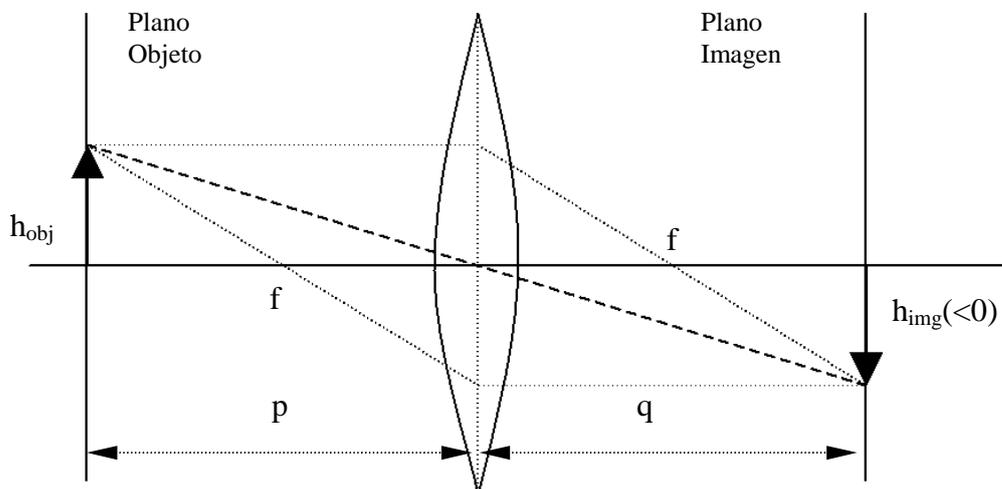
En otros tipos de materiales laminados, los defectos superficiales pueden ser más grandes que el doble del tamaño físico del píxel y esto implica que un defecto en la imagen puede estar formado por cientos de píxeles. En este caso, la detección con este método es robusta debido a que facilita la segmentación de los defectos superficiales, al ocupar el defecto una gran región de la imagen. La desventaja de este método es el reducido área de inspección que se limita al tamaño físico del sensor de imagen en el plano objeto ( $M = 1$ ). Para realizar los cálculos se utiliza el modelo de lente fina, que se muestra a continuación:

$$\frac{1}{p} + \frac{1}{q} = \frac{1}{f}$$

$$M = \frac{-h_{img}}{h_{obj}} = \frac{p}{q}$$

$$DO = f \left( 1 + \frac{1}{M} \right)$$

Donde  $f$  es la distancia focal,  $p$  y  $q$  son las distancias del plano objeto y el plano imagen, respectivamente, a la lente y  $M$  el factor de magnificación; todas estas magnitudes se muestran gráficamente en la figura 4.6.



**Figura 4.6:** Óptica. Modelo de lente fina

En este caso con, magnificación  $M=1$  ( $p=2f$  y  $q=2f$ ), sensor de imagen de 752

píxeles (horizontal)  $\times$  582 píxeles (vertical) y tamaño físico del píxel ( $8,6\mu m \times 8,3\mu m$ ), permite inspeccionar  $6,47\text{mm} \times 4,83\text{mm}$  de superficie. Por tanto, el área de inspección coincide con la superficie activa del sensor de la cámara que se utiliza en los experimentos ( $6,47\text{mm} \times 4,83\text{mm}$ ).

El tamaño mínimo de inspección coincide con el tamaño físico del píxel del sensor utilizado, que es:  $8,6\mu m \times 8,3\mu m$ . Esta resolución permite detectar correctamente en la imagen, por ejemplo, manchas de cascarilla pequeñas de 20 a  $50\mu m$ .

Con respecto a las distancia focales, se han realizado experimentos con  $f = 55\text{ mm}$  y  $f = 160\text{ mm}$ .

Para calcular la profundidad de campo, se utiliza la apertura relativa, o número F ( $F/\#$ ); ésta se define como la relación entre la focal y la apertura:

$$F/\# = \frac{f}{D_{\text{apertura}}}$$

Por definición, un  $F/\#$  grande, implica una apertura relativa pequeña. Un sistema de este tipo se denomina lento, y el contrario rápido, en relación al tiempo de exposición que puede usarse en ellos. A igualdad de focales un sistema con, por ejemplo,  $F/3$  requerirá más tiempo de exposición que un sistema con  $F/1$  para conseguir el mismo nivel de brillo. Pero, como se vio en el apartado anterior, en inspección de microdefectos a alta velocidad es necesario un corto tiempo de exposición, con un nivel de brillo apropiado que permita detectar los microdefectos superficiales. Además, es necesario utilizar un número  $F/\#$  elevado para aumentar la profundidad de campo del sistema físico de inspección, y obedecer la restricción de distancia mínima de seguridad de inspección. Así pues, un sistema de inspección con corto tiempo de exposición y número  $F/\#$  grande está en contraposición. Ésta es una tarea compleja que se soluciona con el sistema láser diseñado, al iluminar fuertemente la pequeña región de inspección.

Resumiendo, la iluminación de una plancha de acero inoxidable u otro material, mediante el sistema láser diseñado, permite aumentar el número  $F/\#$  sin necesidad

de aumentar el tiempo de exposición debido a que el haz láser ilumina fuertemente la pequeña área a inspeccionar (el sistema láser permite utilizar un corto tiempo de exposición con un elevado número  $F/\#$ ). Esto favorece utilizar tiempos de exposición cortos, necesarios en inspección a alta velocidad. Pero también, esta característica del sistema permite aumentar la profundidad de campo hasta valores que evitan una imagen desenfocada frente a ondulaciones o pequeñas variaciones en el grosor de la superficie a inspeccionar.

Si se introducen los valores que se utilizan en los experimentos junto con los de la cámara Sony DXC-950P (apartado 4.3), en la siguiente ecuación, se obtiene la profundidad de campo del sistema (DOF=profundidad de campo="depth of field"):

$$DOF = \frac{2 \cdot TAM_{pix} \cdot F/\# \cdot (1 + M)}{M^2}$$

En el caso de una lente con  $f = 160$  mm, la profundidad de campo es:

$$TAM_{pix} = \text{tamaño físico del píxel en el plano objeto} = 8,6\mu m$$

$$F/\# = \frac{f}{D_{apertura}} = \frac{160mm}{10mm} = 16$$

$$M = 1$$

$$DOF = 0,55mm$$

Los resultados son demasiado restrictivos debido a la pequeña profundidad de campo. En este caso, pequeñas ondulaciones o variaciones de grosor en la plancha de acero inoxidable, desenfocarán la imagen. Para aumentar la profundidad de campo, por ejemplo, se puede reducir el diámetro de apertura y la magnificación. Entonces, si se selecciona un diámetro de apertura de 5 mm (mediante un diafragma) y se aumenta el tamaño a inspeccionar por cada píxel a  $20 \mu m$  (tamaño mínimo de defectos de cascarilla residual), se consigue aumentar la profundidad de campo (DOF) a un valor óptimo para inspección de superficies:

$$M = \frac{8,6\mu m}{20\mu m} = 0,43$$

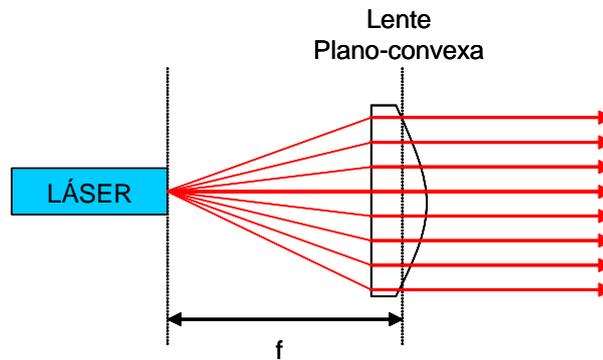
$TAM_{pix}$  = tamaño físico del píxel =  $8,6\mu m$

$$F/\# = \frac{f}{D_{apertura}} = \frac{160mm}{5mm} = 32$$

$$DOF = 4,256mm$$

### 4.2.3. Apertura de haz. Iluminación telecentrica

La siguiente figura 4.7 ilustra el sistema de iluminación telecentrica que se utiliza.



**Figura 4.7:** Iluminación telecentrica

Este sistema se usa para convertir el haz de radiación láser en haces de rayos paralelos, con el objetivo de iluminar de forma telecentrica el difusor. Los rayos están formados por la radiancia de un único punto de luz. En los experimentos se usan lentes plano convexas de 10 mm de diámetro. La lente se sitúa después del láser a una distancia igual a la distancia focal de la lente.

Si la radiancia de la fuente de luz es isótropa dentro del ángulo sólido de la lente, la intensidad emitida por la lente es constante en toda la apertura (10 mm de diámetro). Para distribuciones de radiancia no isótropas, la distribución espacial de intensidad de los rayos emitidos muestra la distribución angular de la radiancia [Jahne et al., 1999].

En el caso de los experimentos realizados con iluminación láser, se trata de

iluminación no isótropa. Pero, la divergencia del haz es de 0,1 y 0,5 mrad, esta característica permite abrir el haz láser lo suficiente antes de llegar a la lente plano-convexa.

En las pruebas realizadas, la pequeña apertura del haz, los rayos paralelos que forma la lente plano-convexa y la posterior utilización de un difusor giratorio permiten iluminar de forma difusa la superficie a inspeccionar.

### **4.3. Cámara Sony DXC-950P**

La cámara de video color DXC-950P 3-CCD captura imágenes de alta calidad gracias a tres Power HAD CCD. La cámara posee tres características que garantizan la calidad de la imagen:

- La resolución horizontal: 750 líneas de TV.
- La sensibilidad (mínima iluminación requerida): 2000 lux con apertura F8.5.
- Alto ratio Señal / Ruido: 58 dB.

La cámara posee dos funciones apropiadas para la realización de los experimentos: AGC (Automatic Gain Control) control automático de ganancia del sensor y “CCD iris control”. Con estas dos funciones la cámara puede adquirir imágenes bajo distintas condiciones de iluminación. Cuando la imagen se toma en condiciones de poca iluminación, el AGC automáticamente incrementa la sensibilidad hasta 8 veces. En el caso de luz excesiva, el “CCD iris control” automáticamente incrementa la velocidad del disparador (“shutter”) para reducir el tiempo de exposición. Esta función puede reducir la exposición equivalentemente a la reducción de hasta 6 números F/#.

El amplio rango de velocidades del disparador (“shutter”) electrónico ayuda a tomar imágenes en condiciones difíciles, minimiza las imágenes borrosas de superficies moviéndose rápidamente y produce imágenes claras de defectos superficiales capturados con poca iluminación.

Las características más importantes de la cámara son las siguientes:

- CCD de media pulgada, de tipo transferencia interlinea.
- 752 (horizontal)×582(vertical) píxeles efectivos.
- Formato de señal PAL.
- 750 líneas de resolución horizontal.
- Sensibilidad: 2000 lux (F8.5, 3200K).
- Ratio señal ruido: 58 dB.
- Control de ganancia
  - Automático.
  - Manual: 0 – 18 dB en pasos de 1 dB.
  - ISO sensibilidad: 400, 800 o 1600.
- Balance de blancos
  - Automático.
  - Manual.
  - ATW: El balance de blancos se ajusta automáticamente cuando la temperatura del color cambia.
- Velocidad del disparador (“shutter”) electrónico: Ajustable en el rango de 1/10000 seg. a 10 seg.
- Compensación gamma: On/Off.
- Modo de acumulación de carga: modo campo o imagen.

Las imágenes capturadas con la óptica convencional de la cámara no muestran los defectos de cascarilla residual. Por otro lado, al inspeccionar una superficie grande y detectar defectos muy pequeños es necesario iluminar fuertemente toda la región. Entonces, para conseguir una buena imagen con esta cámara y detectar los pequeños defectos superficiales, hace falta una óptica de alto coste (por ejemplo, una óptica telecentrica) e iluminación difusa de toda la región.

Con el objetivo de mostrar las imágenes capturadas con esta cámara se realizaron varias pruebas. Las dos primeras imágenes (fig. 4.8a-b) son el resultado de inspeccionar una superficie de acero inoxidable con defectos de cascarilla residual. Donde

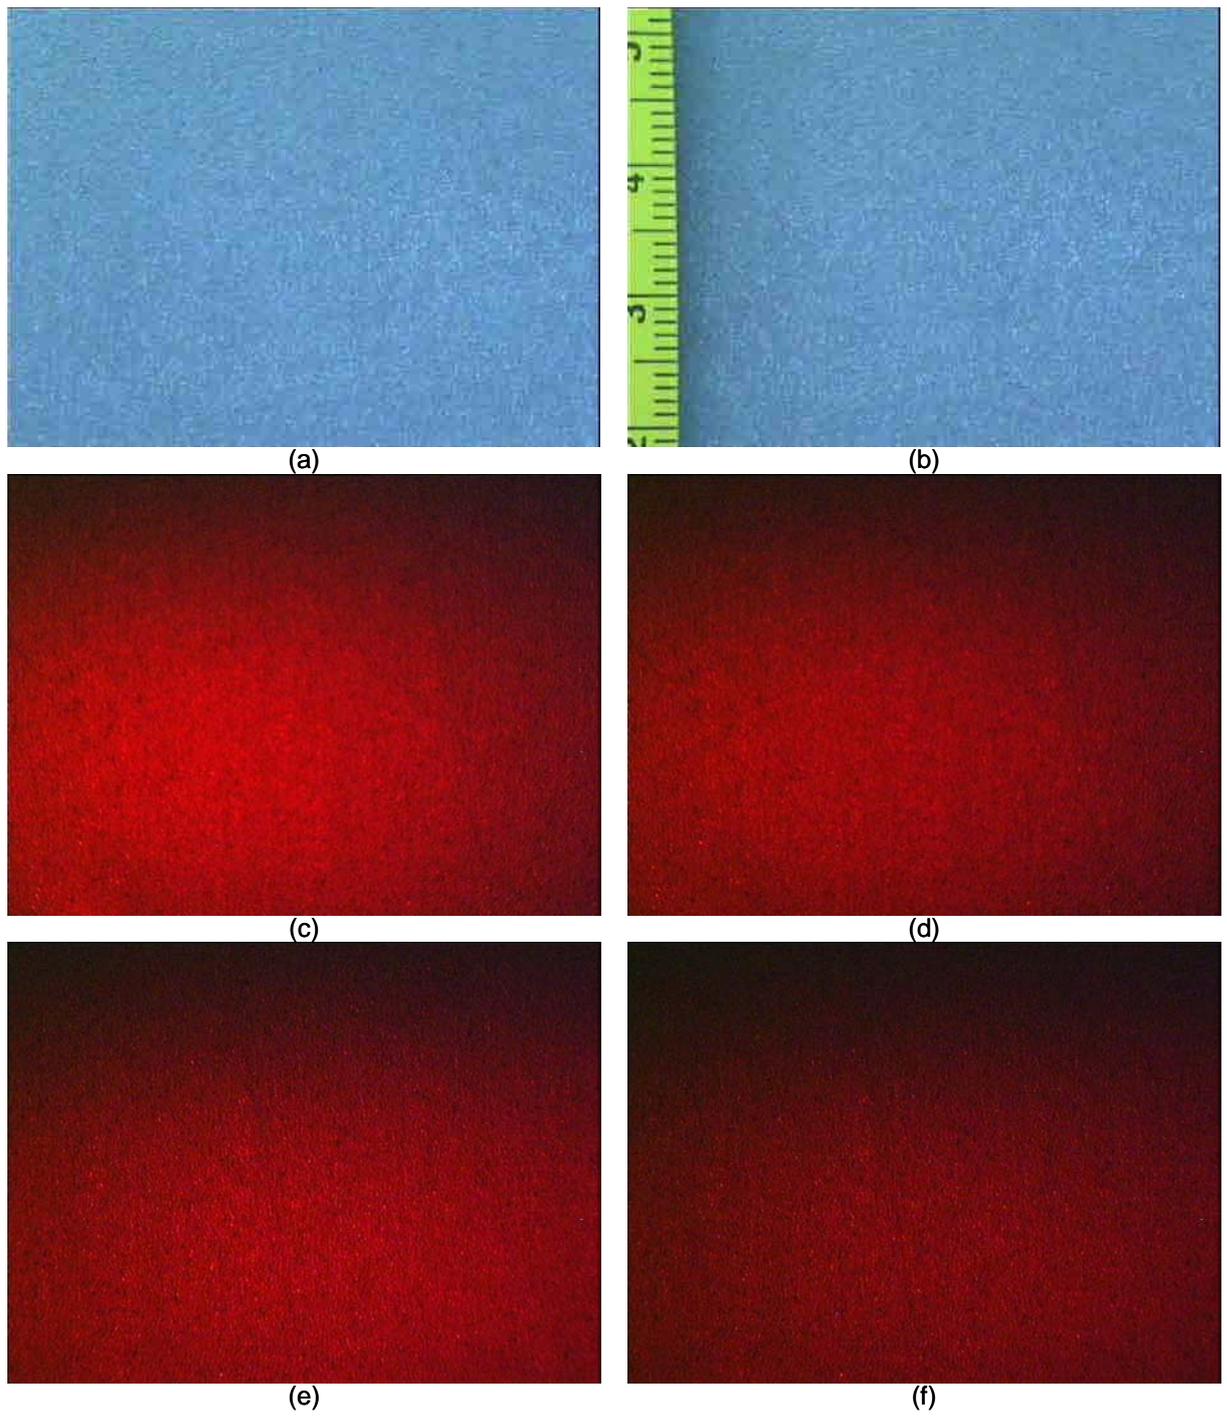
se utiliza iluminación y óptica convencional. Como se puede observar es imposible detectar este defecto debido a su reducido tamaño [ $100 - 1000 \mu m$ ] en una imagen que inspecciona aproximadamente  $30 \times 40$  mm de acero inoxidable. Los siguientes experimentos (fig. 4.8c-f) se realizan con iluminación láser y óptica convencional pero tampoco se consiguen buenos resultados.

Los resultados de inspección con elementos convencionales (óptica e iluminación) no son satisfactorios. En conclusión, es necesario utilizar elementos de iluminación y óptica de alto coste para detectar defectos superficiales pequeños en acero inoxidable. Pero esto está en contraposición con la industria, debido a que una inspección superficial completa del ancho de la línea de producción implica un coste muy elevado. En el siguiente apartado, se presenta una solución viable para la industria con resultados óptimos de inspección de defectos superficiales. En concreto, para demostrar su viabilidad, se detectan defectos en superficies de acero inoxidable. Pero también se pueden inspeccionar diferentes tipos de defectos y superficies con el objetivo de adaptarse a diferentes entornos. Por ejemplo, inspección de acero inoxidable con defectos superficiales de cascarilla residual, inspección de madera con grietas o pequeñas fisuras, etc.

## **4.4. Formación de imagen**

Este apartado muestra los experimentos realizados con dos sistemas de iluminación láser para inspección de superficies. El primer sistema se basa en iluminación láser difusa y coaxial. El segundo en iluminación láser difusa formando un ángulo de  $30$  a  $45^\circ$  entre el eje óptico del sistema y el haz láser difuso.

En la literatura se encuentran diversos sistemas con iluminación láser. Por ejemplo, en inspección de calidad de la superficie de alambres metálicos [Siegmann et al., 2004a], [Siegmann et al., 2004b], [Quintian et al., 1997] se utiliza la reflexión de un haz láser en la superficie de un alambre metálico. Esto proporcio-



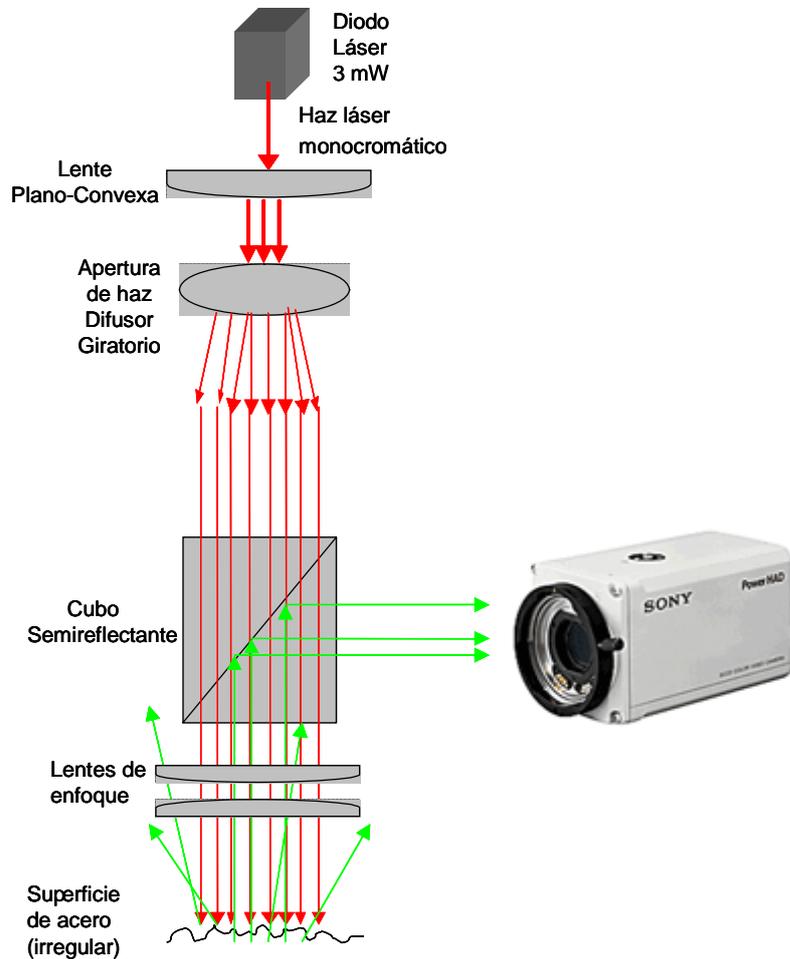
**Figura 4.8:** (a-b) Imágenes capturadas con cámara SONY, y óptica e iluminación convencional, (c-f) Imágenes capturadas con cámara SONY, óptica convencional e iluminación láser

na un método eficiente para inspeccionar la calidad de este tipo de superficies. En este estudio, el objetivo es la detección de defectos orientados axialmente y presentan un modelo geométrico-interferencial simple para describir el patrón de luz reflejado por un alambre con defectos. En otro trabajo, se estudian las olas que produce un rompeolas en un tanque de agua a partir de iluminación láser [Schlicke, 2001]. En este experimento se ilumina el agua utilizando un haz láser, un espejo octogonal rotatorio y un espejo parabólico.

#### **4.4.1. Iluminación láser coaxial**

El primer sistema diseñado para inspección de superficies está basado en iluminación láser coaxial. El sistema se prueba en la detección de cascarilla residual en planchas de acero inoxidable. La formación de imagen se realiza mediante una lente plano-convexa de focal 160 mm o 55 mm. La divergencia del haz láser es muy pequeña, pero suficiente para abrir el haz que posteriormente ilumina la superficie a inspeccionar. El haz se corrige con una lente plano-convexa que consigue iluminación telecentrica (rayos paralelos pero más separados que inicialmente a la salida del láser). El láser se sitúa en el foco de la lente plano-convexa. Si únicamente se utilizan estos elementos ópticos, como se comentó anteriormente, se genera un patrón de interferencia al iluminar la superficie a inspeccionar. Este ruido de interferencia “speckle” se elimina mediante un difusor giratorio. El difusor también se encarga de abrir el haz colimado que proviene de la lente plano-convexa e iluminar la región de inspección. El siguiente componente óptico permite iluminar y recibir la luz reflejada de la superficie a inspeccionar por el mismo camino óptico. Este elemento se denomina cubo divisor de haz. El primer haz que llega al cubo es el del láser, que lo deja pasar en dirección a la superficie a inspeccionar y no a la cámara. El segundo haz que llega al cubo es el reflejado por la superficie a inspeccionar que pasa a la cámara. El último componente óptico son las lentes de enfoque que permiten formar la imagen en el plano imagen de la cámara. La figura 4.9 muestra un esquema de

este sistema con la cámara Sony DXC-950P situada en el plano de formación de la imagen. Los haces de iluminación en dirección a la superficie a inspeccionar se dibujan en color rojo y los haces reflejados hacia la cámara en color verde.



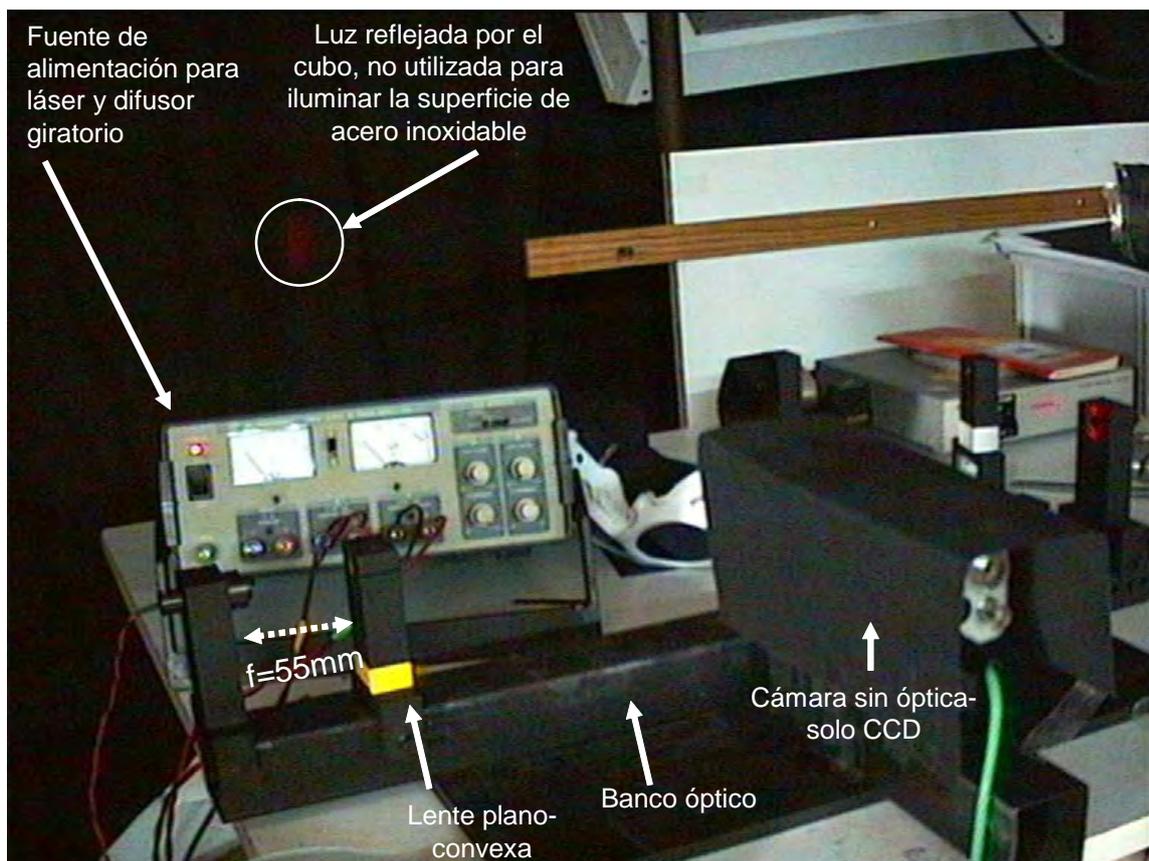
**Figura 4.9:** Sistema de iluminación láser coaxial

#### 4.4.1.1. Sistema físico

El banco óptico donde se realizan los experimentos se ha diseñado en acero inoxidable y pintado de color negro mate para evitar reflejos de luz. Los primeros experimentos se realizaron con el banco óptico recién fabricado (sin pintar de negro mate, fig. 4.10). Esto permitió observar que los bordes de las estructuras de sujeción

de las lentes reflejan gran cantidad de luz. Lo que dificulta tomar una imagen clara de la superficie a inspeccionar.

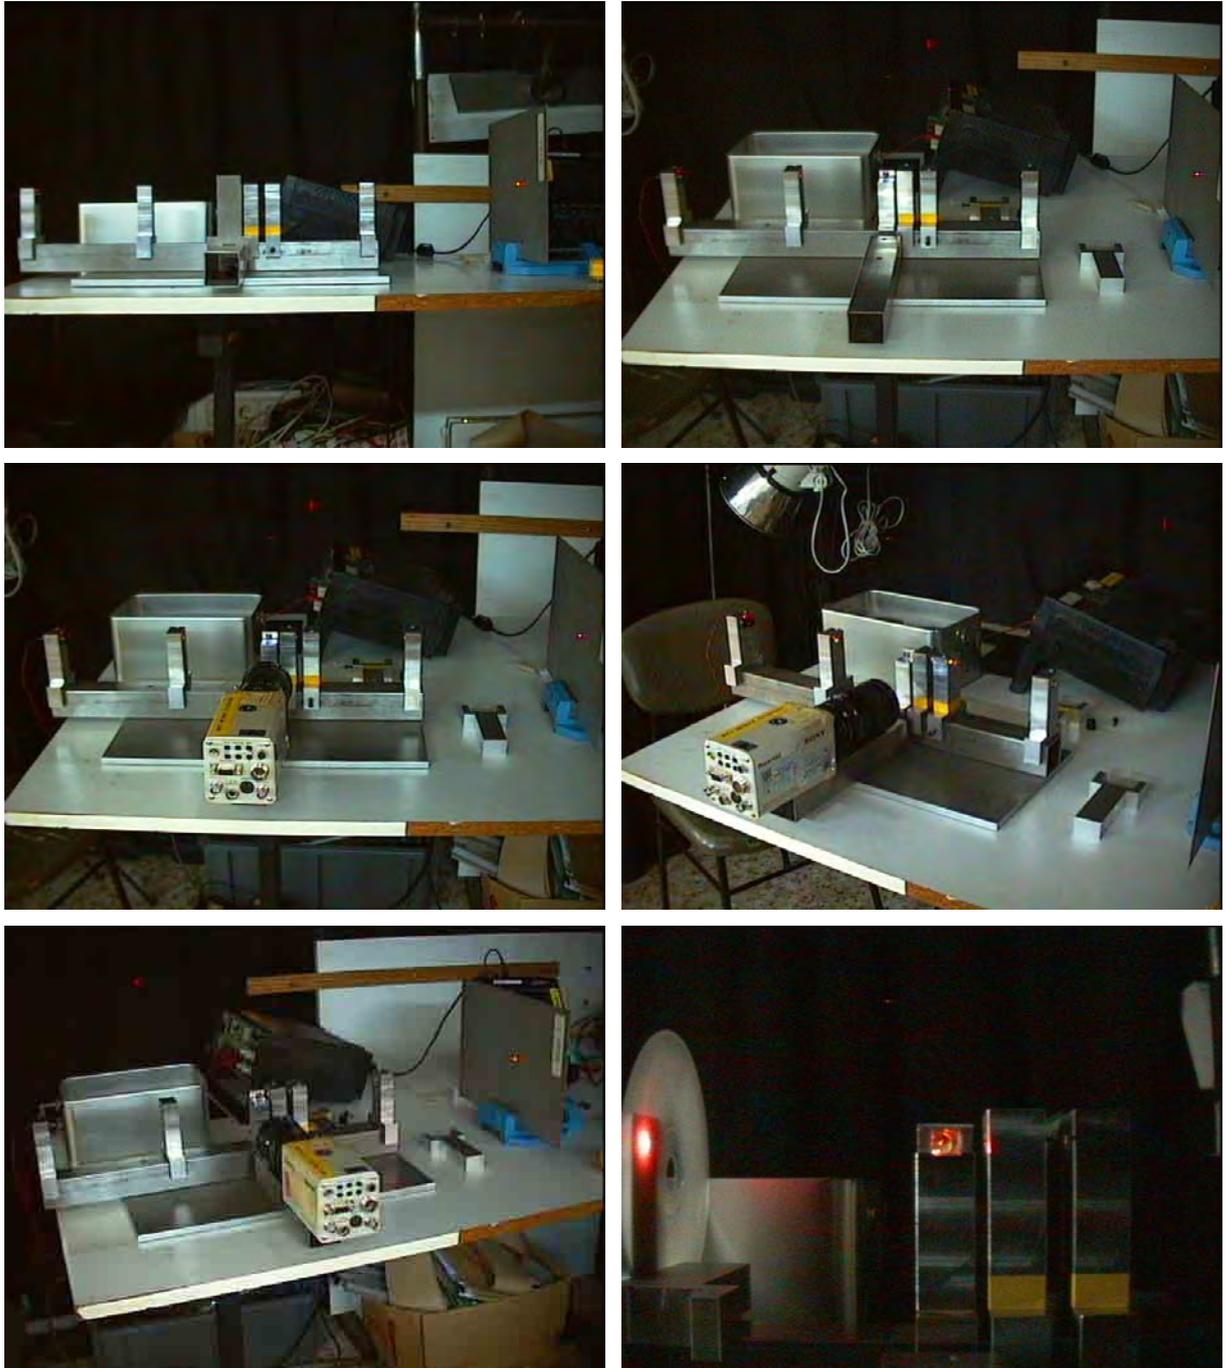
Las figuras 4.11, 4.12 y 4.13 muestran una primera configuración del sistema sin difusor. Sobre las imágenes se indican los elementos constituyentes del sistema.



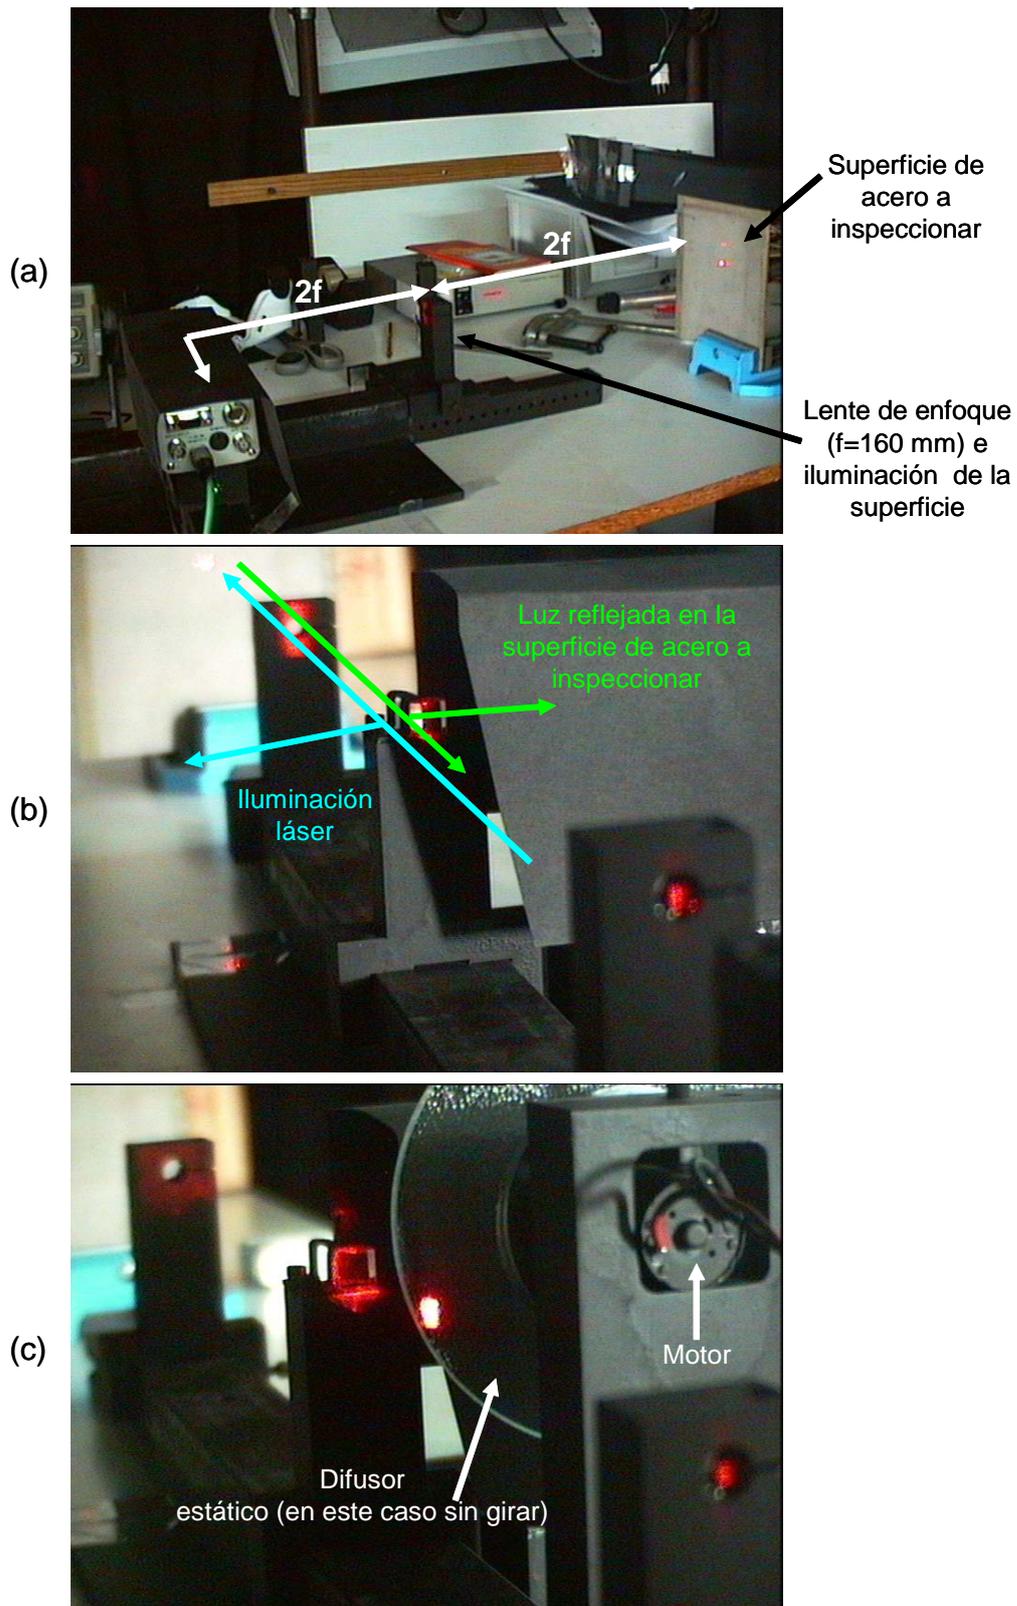
**Figura 4.11:** Sistema para iluminación láser de la superficie a inspeccionar sin utilizar difusor giratorio

#### 4.4.1.2. Experimentos preliminares

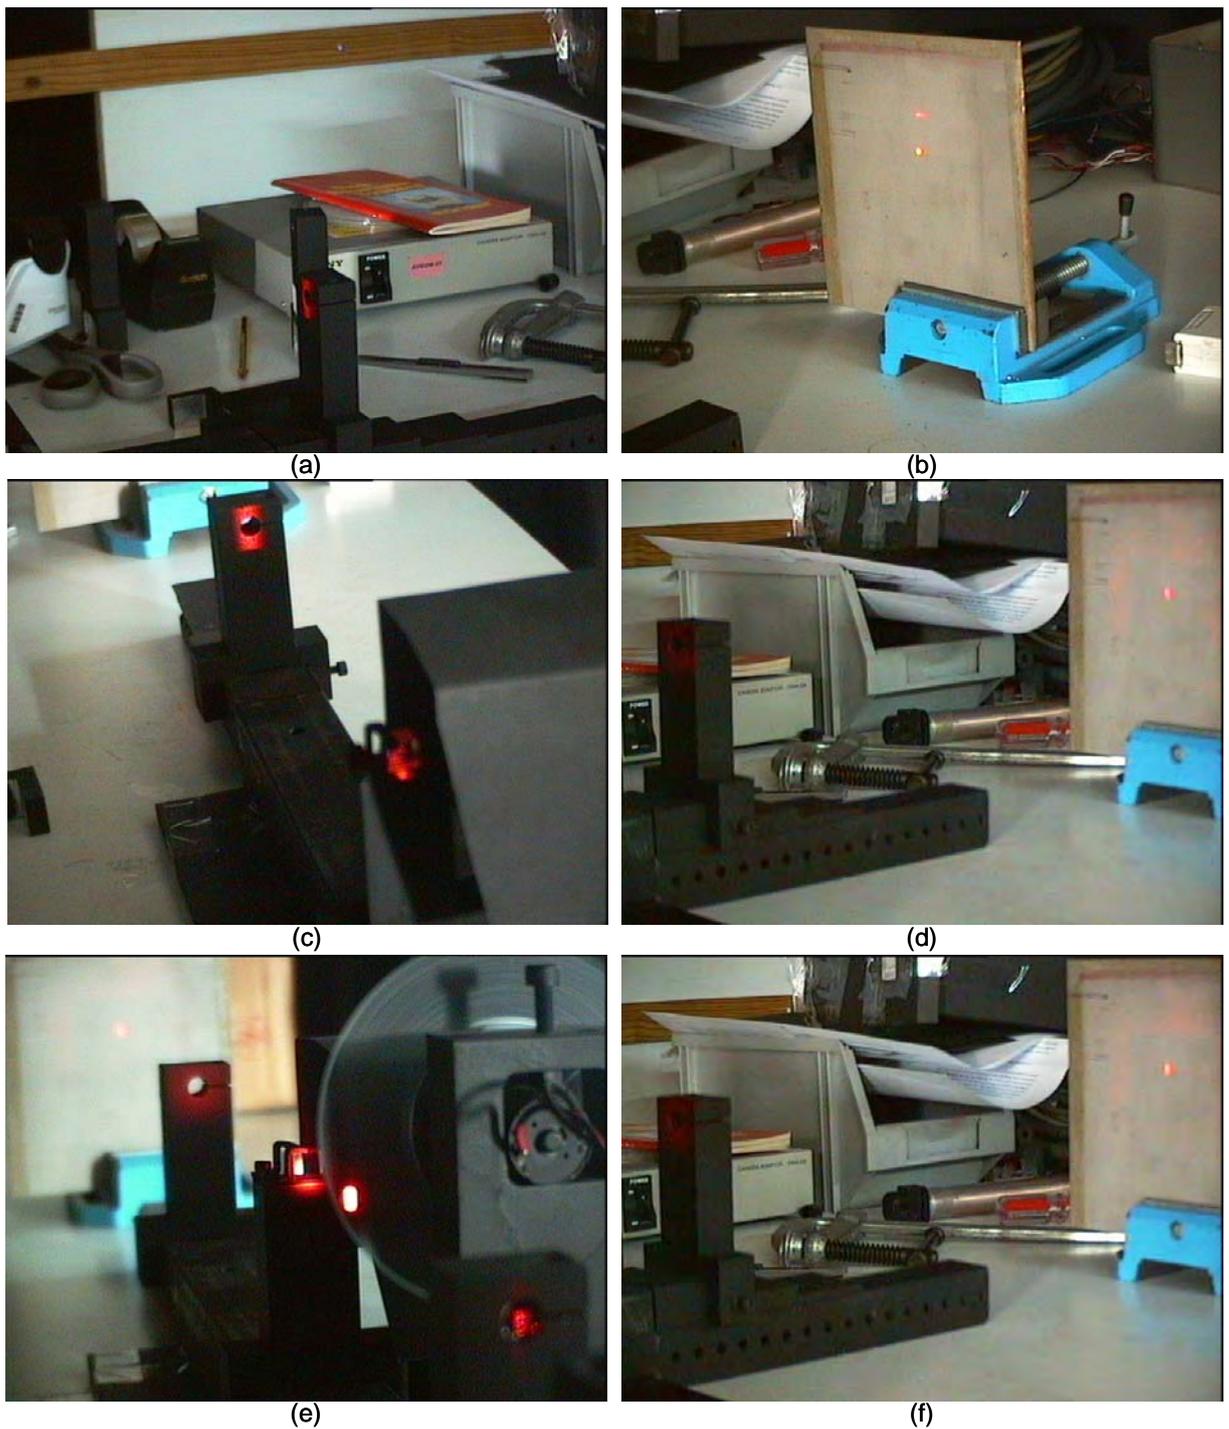
El sistema de iluminación coaxial se prueba en la detección de defectos de cascarrilla residual en planchas de acero inoxidable. Los primeros experimentos con esta configuración no muestran los defectos debido a problemas de interferencias lumino-



**Figura 4.10:** Banco óptico recién salido del taller mecánico y primeras pruebas de funcionamiento



**Figura 4.12:** (a) Sistema de enfoque con  $M=1$  y lente plano-convexa ( $f=160$ mm), (b) Esquema de haces incidente y reflejado, (c) Iluminación con difusor estático



**Figura 4.13:** (a) Lente plano-convexa de enfoque (la estructura que la sujeta actúa también de diafragma), (b) Detalle de la superficie iluminada, (c) Haz láser que atraviesa el cubo semireflectante y la lente de enfoque, (d) Iluminación de la plancha de acero con difusor estático, (e) Iluminación con difusor girando, (f) Superficie iluminada con el difusor girando

sas y ruido “speckle”. Estas pruebas fallidas se muestran como preámbulo o camino hacia una correcta adquisición con iluminación coaxial (en el siguiente apartado, se muestran las imágenes con los defectos de cascarilla residual detectados). Las inspecciones, en este caso preliminar, se realizan con una lente de enfoque de distancia focal 55 mm y 160 mm. A continuación, se resumen los experimentos realizados y sus conclusiones:

- Experimento 1;  $f = 55$  mm; sistema con difusor estático, cubo y lente de enfoque.

El primer experimento captura una imagen de la superficie de acero inoxidable a inspeccionar, mediante el sensor CCD de la cámara Sony. Los resultados no son satisfactorios debido a interferencias que dificultan la visualización de los defectos de cascarilla residual. En estos experimentos se han utilizado planchas de acero inoxidable con abundante cascarilla con el objetivo de facilitar su detección. La imagen obtenida se muestra en la figura 4.14a. En este primer experimento se deja el difusor estático (sin giro). Esta configuración consigue eliminar parte del ruido pero no completamente.

- Experimento 2;  $f = 55$  mm; sistema con difusor girando, cubo y lente de enfoque.

En este experimento se utiliza el difusor girando, con el objetivo de eliminar el ruido “speckle” producido por la iluminación láser. La figura 4.14b muestra los resultados. Así, se consigue eliminar el ruido, pero no se observan las manchas de cascarilla.

- Experimento 3;  $f = 55$  mm; sistema con sólo cubo.

El siguiente experimento caracteriza las interferencias producidas sólo por el cubo semireflectante. Así, se permite al haz láser llegar sólo al cubo y no pasar ni a la lente de enfoque ni a la superficie de acero a inspeccionar. Los resultados

(fig. 4.14c) muestran un patrón de interferencias debido a la luz reflejada en el cubo que llega al sensor CCD.

- Experimento 4;  $f = 55$  mm; sistema con cubo y lente de enfoque.

El siguiente experimento muestra ruido “speckle” e interferencias debido al cubo, lente de enfoque y superficie de acero. Se muestran tres imágenes y de nuevo no se puede determinar la existencia de cascarilla debido al ruido (fig. 4.14d-f).

- Experimento 5;  $f = 160$  mm; sistema con cubo y lente de enfoque.

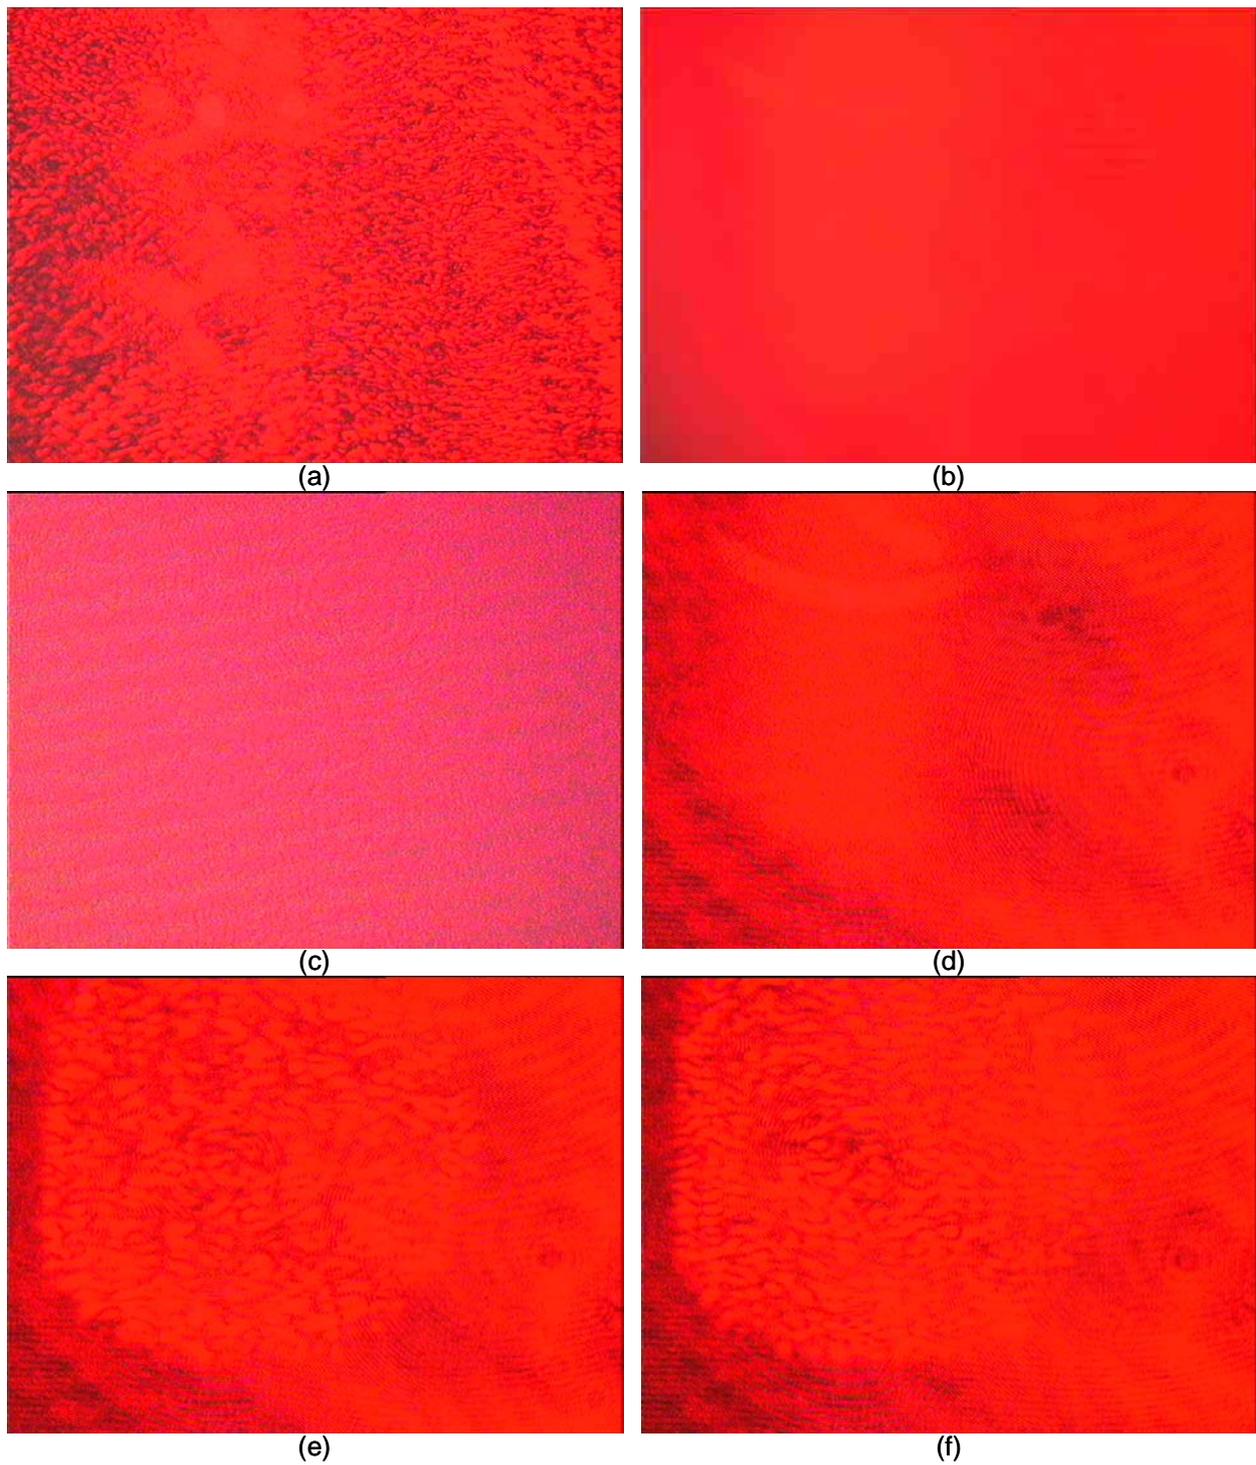
El primer experimento de iluminación láser coaxial con una lente de enfoque de distancia focal 160 mm y sin difusor, mostró resultados esperanzadores en la detección de las manchas de cascarilla que existían en la plancha de acero (fig. 4.15a). Pero, las manchas oscuras que se observan en esta figura no son cascarilla residual. Las manchas pertenecen al patrón de interferencia debido a la iluminación láser. Esto se demostró quitando la plancha de acero a inspeccionar y observando la nueva imagen (fig. 4.15b). Esta imagen es igual a la anterior. Por lo tanto, las manchas oscuras son debidas al patrón de interferencia y no a la presencia de cascarilla en la plancha de acero.

- Experimento 6;  $f = 160$  mm; sistema con sólo cubo.

En el siguiente experimento se realiza una nueva prueba sólo con el cubo en el sistema óptico (fig. 4.15c). Por tanto, se observa un patrón parecido al que se vio en el experimento 3.

- Experimento 7;  $f = 160$  mm; sistema con difusor, cubo y lente de enfoque.

El siguiente experimento estudia la imagen formada en el CCD, situado en el plano imagen, con el sistema óptico coaxial completo compuesto por lente de apertura, difusor estático, cubo semireflectante y lente de enfoque. Los



**Figura 4.14:** (a) Imagen tomada con iluminación coaxial. Se observa ruido “speckle”, (b) Eliminación completa de ruido “speckle” en la imagen, (c) Interferencia debida a luz láser procedente del cubo semireflectante, (d-f) Ruido de speckle en el sistema de iluminación láser coaxial

resultados (fig. 4.15d) muestran ruido “speckle” debido a la iluminación láser. Es difícil determinar si existen manchas de cascarilla en la imagen.

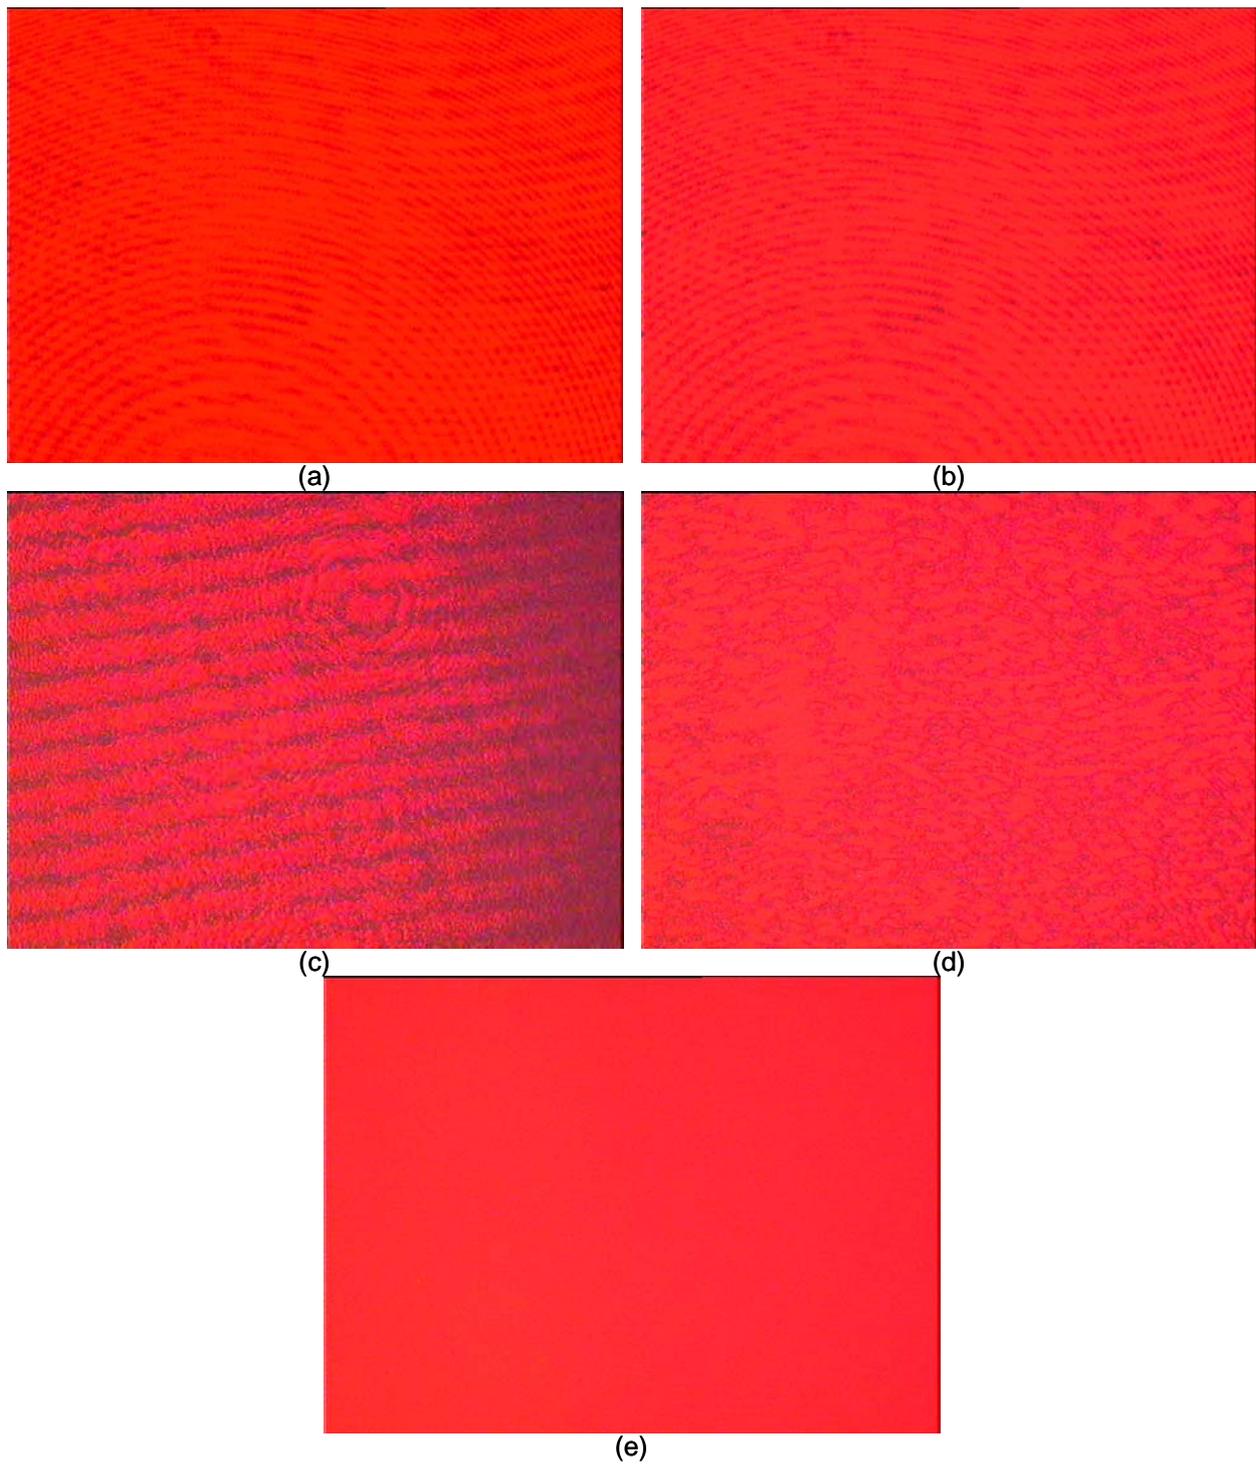
- Experimento 8;  $f = 160$  mm; sistema con difusor girando, cubo y lente de enfoque.

Finalmente, se utiliza la misma configuración que en el experimento anterior, pero en este caso se activa el giro del difusor. La figura 4.15e muestra la imagen sin ruido speckle debido a la utilización del difusor giratorio. Se elimina el ruido, pero siguen sin observarse las manchas de cascarilla que existen en la plancha de acero inspeccionada.

#### 4.4.1.3. Detección de cascarilla residual

La configuración coaxial que consigue detectar los defectos de cascarilla residual se muestra en la figura 4.16a-b. Ésta consiste en apertura del haz, difusor girando, cubo semireflectante, lente de enfoque con focal 55 mm y magnificación  $M = 1$ .

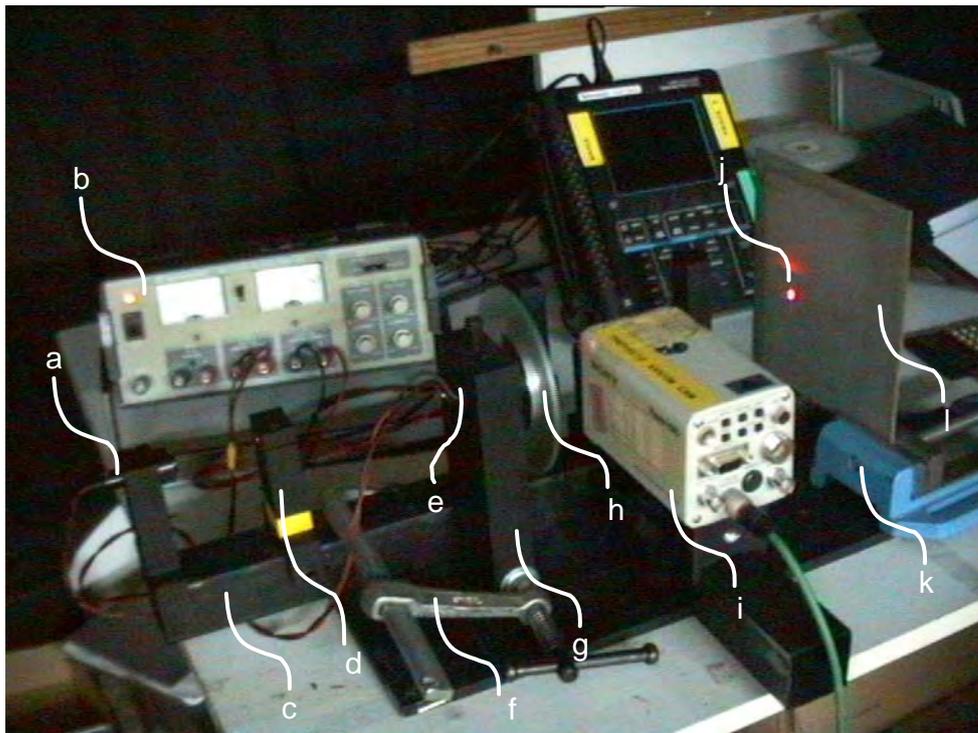
La distancia entre la plancha de acero y la lente de enfoque es de 110 mm =  $2f$ . En este apartado de viabilidad del método de iluminación podemos utilizar esta distancia, pero ésta es pequeña y tiene que ser mayor o igual a 300 mm para estar dentro del rango de seguridad. Como se comentará más adelante, la primera solución a este problema de distancia de seguridad es aumentar la distancia de separación utilizando una lente de enfoque de 160 mm, así se consigue que la distancia entre la plancha de acero y la lente sea de 320 mm (magnificación  $M = 1$ ). Pero con esta solución, la iluminación del láser rojo no es suficiente para esta nueva distancia y la imagen aparece oscura donde no se aprecia ni el acero inoxidable ni los defectos de cascarilla residual. Para solucionar este nuevo problema de iluminación se utilizará un láser verde de alta luminosidad que es capaz de iluminar la superficie utilizando una lente de enfoque de 160 mm y por tanto permite inspeccionar dentro de la distancia de seguridad ( $\geq 300$  mm).



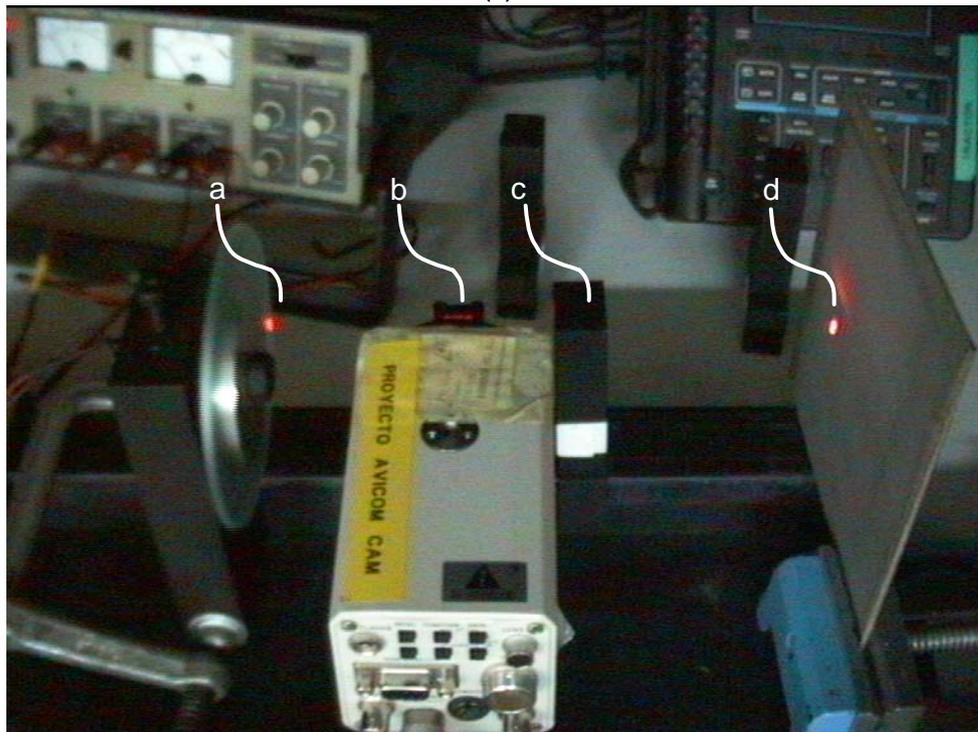
**Figura 4.15:** (a) Patrón de interferencia debido a iluminación láser, sin difusor y lente de  $f=160\text{mm}$ , (b) Patrón de interferencia, sin plancha de acero a inspeccionar, (c) Patrón de interferencia generado por el cubo semireflectante, (d) “Speckle” en el sistema óptico coaxial completo, (e) Eliminación de ruido “speckle” debido al giro del difusor

Por tanto, en el laboratorio se han realizado pruebas con iluminación láser rojo para demostrar la detección de cascarilla, pero como se verá en el último capítulo, en el diseño industrial se utiliza iluminación láser verde. La figura 4.16a muestra en detalle la disposición de los componentes del sistema de inspección basado en iluminación láser: 4.16a<sup>a</sup> láser rojo en un soporte del banco óptico, 4.16a<sup>b</sup> fuente de alimentación para el láser rojo y motor del difusor, 4.16a<sup>c</sup> banco óptico donde se sujetan los soportes del láser, lentes, cámara, etc., 4.16a<sup>d</sup> lente para iluminación telecentrica, 4.16a<sup>e</sup> motor de corriente continua para giro del difusor, 4.16a<sup>f</sup> prensa para fijar el soporte del motor y difusor al banco óptico, 4.16a<sup>g</sup> soporte del motor y difusor, 4.16a<sup>h</sup> disco difusor de cristal, 4.16a<sup>i</sup> cámara (sin óptica) para adquisición de imagen, 4.16a<sup>j</sup> superficie de la plancha de acero inoxidable iluminada por el haz láser rojo, 4.16a<sup>k</sup> soporte de la plancha de acero inoxidable y 4.16a<sup>l</sup> plancha de acero inoxidable. Por otro lado, la figura 4.16b muestra la siguiente información relativa al haz de iluminación: 4.16b<sup>a</sup> haz láser difuso a la salida del difusor, 4.16b<sup>b</sup> haz láser en el cubo semireflectante, 4.16b<sup>c</sup> lente de enfoque con distancia focal 55 mm y 4.16b<sup>d</sup> superficie iluminada a inspeccionar por el sistema coaxial en la plancha de acero inoxidable.

El primer resultado de inspección se muestra en la figura 4.17. Los defectos de cascarilla residual se aprecian en el centro de la imagen. La captura de imagen sólo se produce en la franja vertical del centro de la imagen. Esto se debe a que el plano vertical del cubo semireflectante no es completamente paralelo al plano del sensor CCD de la cámara, y la imagen aparece cortada en los extremos de la dirección  $x$ . Sin embargo, el plano horizontal del cubo es perpendicular al plano del sensor CCD, por lo tanto, en la dirección  $y$  aparece totalmente la imagen. Por otro lado, la captura de imagen se consigue reduciendo la ganancia del sensor de la cámara al mínimo (0 dB). En los primeros experimentos se eliminaba el ruido “speckle” pero la fuerte iluminación láser saturaba los píxeles de la cámara. Esto se debe a los píxeles de la imagen pertenecientes al acero inoxidable, al saturarse provocan que sus vecinos también se llenen (“blooming”). De esta forma se enmascara el resto de



(a)



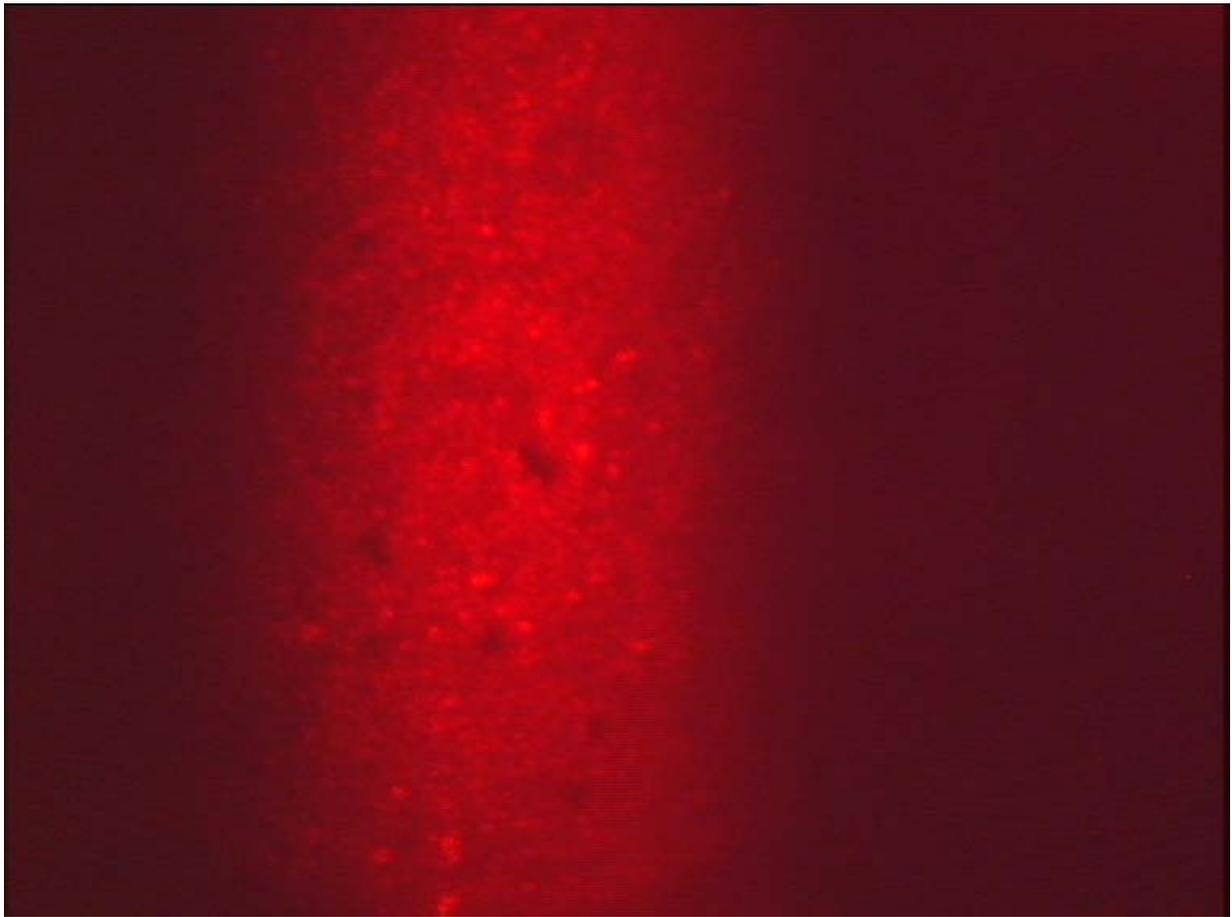
(b)

**Figura 4.16:** (a) Configuración para inspección coaxial con lente de enfoque de distancia focal 55 mm, (b) Detalle del haz láser en las distintas partes del sistema de inspección coaxial, para detección de defectos de cascarilla en acero inoxidable.

información (píxeles de cascarilla residual). En este caso, al reducir la ganancia al mínimo no se llegan a saturar los píxeles pertenecientes al acero inoxidable y los píxeles de cascarilla residual se observan correctamente (fig. 4.17).

Por otro lado, en condiciones de inspección a alta velocidad, se aprovecha esta fuerte iluminación sin reducir la ganancia del sensor de la cámara para capturar imágenes óptimas. Así, la saturación que enmascaraba los defectos superficiales a plancha parada, resulta útil para inspección de superficies a alta velocidad, ya que, nos permite disminuir el tiempo de exposición ( $t_{exp} \downarrow$ ) y aumentar el número  $F/\#$  ( $F/\# \uparrow$ ) para detectar microdefectos superficiales a alta velocidad.

Estos resultados o conocimiento adquirido en la solución del problema de inspección de microdefectos de cascarilla residual, permite diferenciar tipos de conocimiento genérico del dominio de inspección de superficies que posteriormente utiliza la arquitectura ARDIS, por ejemplo, el tipo de conocimiento de tiempo-real (capítulo 5).

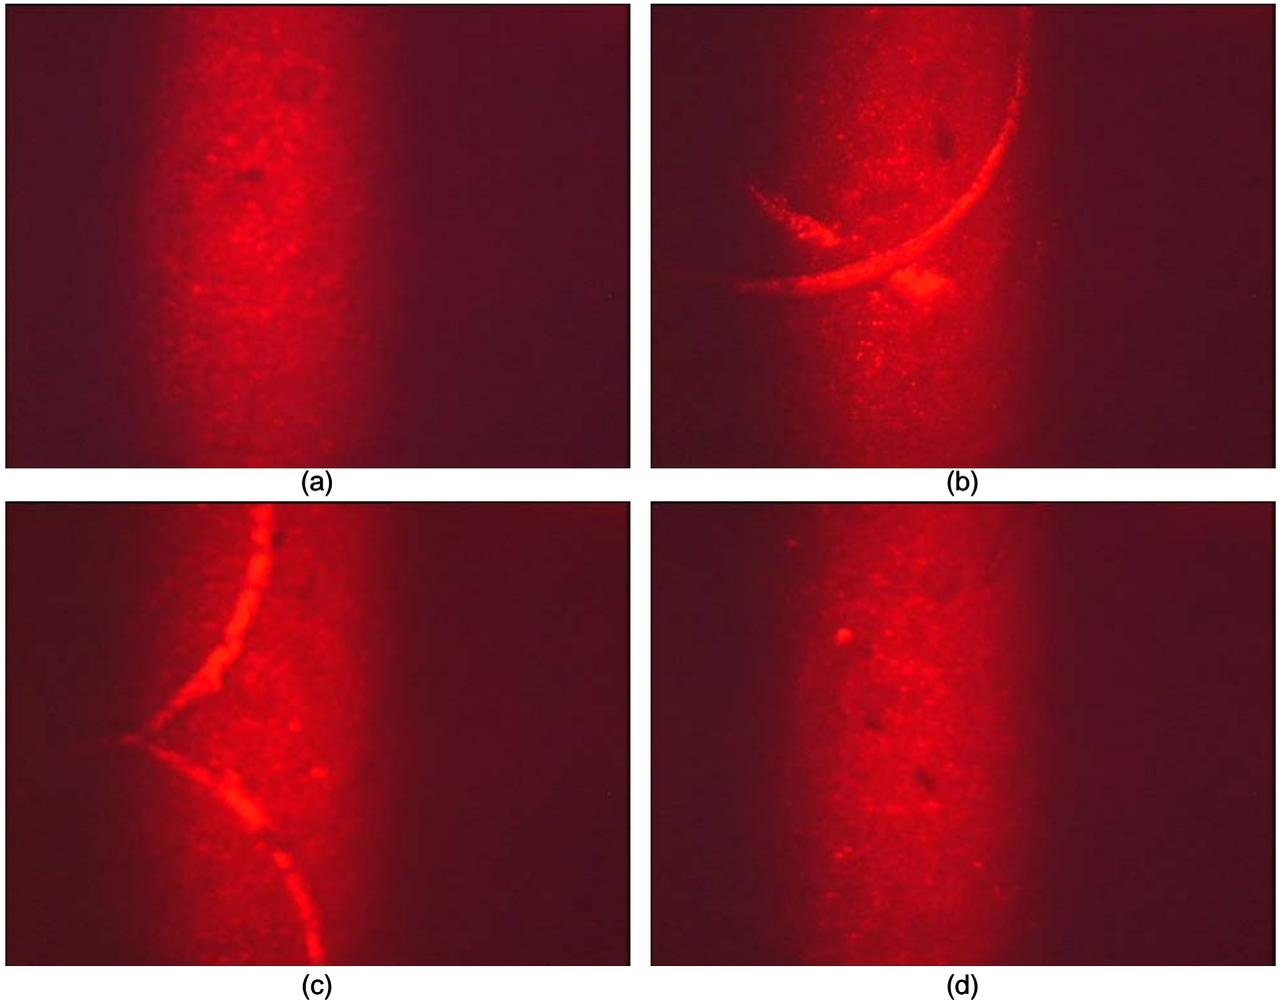


**Figura 4.17:** Detección de cascarilla residual con el sistema de inspección láser coaxial

En la figura 4.18 se observa un conjunto de resultados con este método de iluminación láser coaxial. La imagen 4.18a y 4.18d muestran la detección de cascarilla residual en una plancha de acero inoxidable. Las imágenes 4.18b y 4.18c también muestran la detección de defectos superficiales de cascarilla y parte de un número 3 grabado en la superficie de la plancha de acero inoxidable.

#### **4.4.2. Iluminación láser exterior**

En este caso, la formación de imagen se lleva a cabo mediante iluminación láser exterior (formando un ángulo de 30 a 45°, entre el haz láser y la cámara). La configu-



**Figura 4.18:** Conjunto de imágenes con defectos de cascarilla residual y parte de un número 3 grabado en la superficie de la plancha de acero inoxidable

ración de los elementos en el banco óptico es distinta a la anterior y no utiliza cubo semireflectante. El haz láser para iluminación difusa de la superficie se genera igual que en el caso anterior, pero ahora en vez de dirigirlo hacia el cubo semireflectante, se dirige directamente a la superficie a inspeccionar. El enfoque se sigue realizando con una lente simple y la captura de imagen con los mismos componentes: cámara SONY (sin óptica) y tarjeta de adquisición Matrox Meteor.

#### **4.4.2.1. Sistema físico**

El sistema de iluminación exterior está compuesto por el modulo de iluminación (láser, lente para iluminación telecentrica y difusor giratorio) y el de adquisición de imagen (sensor CCD de la cámara SONY y lente de enfoque). El haz láser ilumina directamente la superficie de acero inoxidable, formando un ángulo de  $30^\circ$  con respecto a la cámara (fig. 4.19a). La disposición de los elementos se observa en la imagen: 4.19a<sup>a</sup> protector negro para que el CCD de la cámara sólo reciba luz procedente de la lente de enfoque y no de otras fuentes de luz exteriores, 4.19a<sup>b</sup> modulo de iluminación láser y 4.19a<sup>c</sup> superficie de acero inoxidable a inspeccionar. El detalle del modulo de iluminación láser se observa en la figura 4.19b y está compuesto en este caso por un láser rojo (fig. 4.19b<sup>a</sup>), una lente para iluminación telecentrica (fig. 4.19b<sup>b</sup>) y un difusor giratorio para eliminar el ruido “speckle” (fig. 4.19b<sup>c</sup>). El sensor CCD de la cámara (con lente de enfoque y  $M=1$ ) inspecciona una superficie de (6.47mm  $\times$  4.83mm), por lo tanto, sólo es necesario iluminar apropiadamente esta región. En la figura 4.19c<sup>a</sup> se ve la superficie iluminada por el láser y ésta es suficiente para detectar los defectos de cascarilla residual en la región inspeccionada de la plancha de acero. Por tanto, este método de iluminación se puede integrar en el entorno industrial debido a su bajo coste y robustez. También, en la figura 4.19d se muestra desde otra perspectiva como el haz láser pasa de ser un pequeño haz colimado a un haz láser difuso que ilumina la superficie de inspección. Por otro lado, la figura 4.19e<sup>a</sup> muestra la tapa negra que cubre la cámara con el CCD descubierto y la pequeña abertura para la lente de enfoque de 10 mm de diámetro (figura 4.19e<sup>b</sup>).

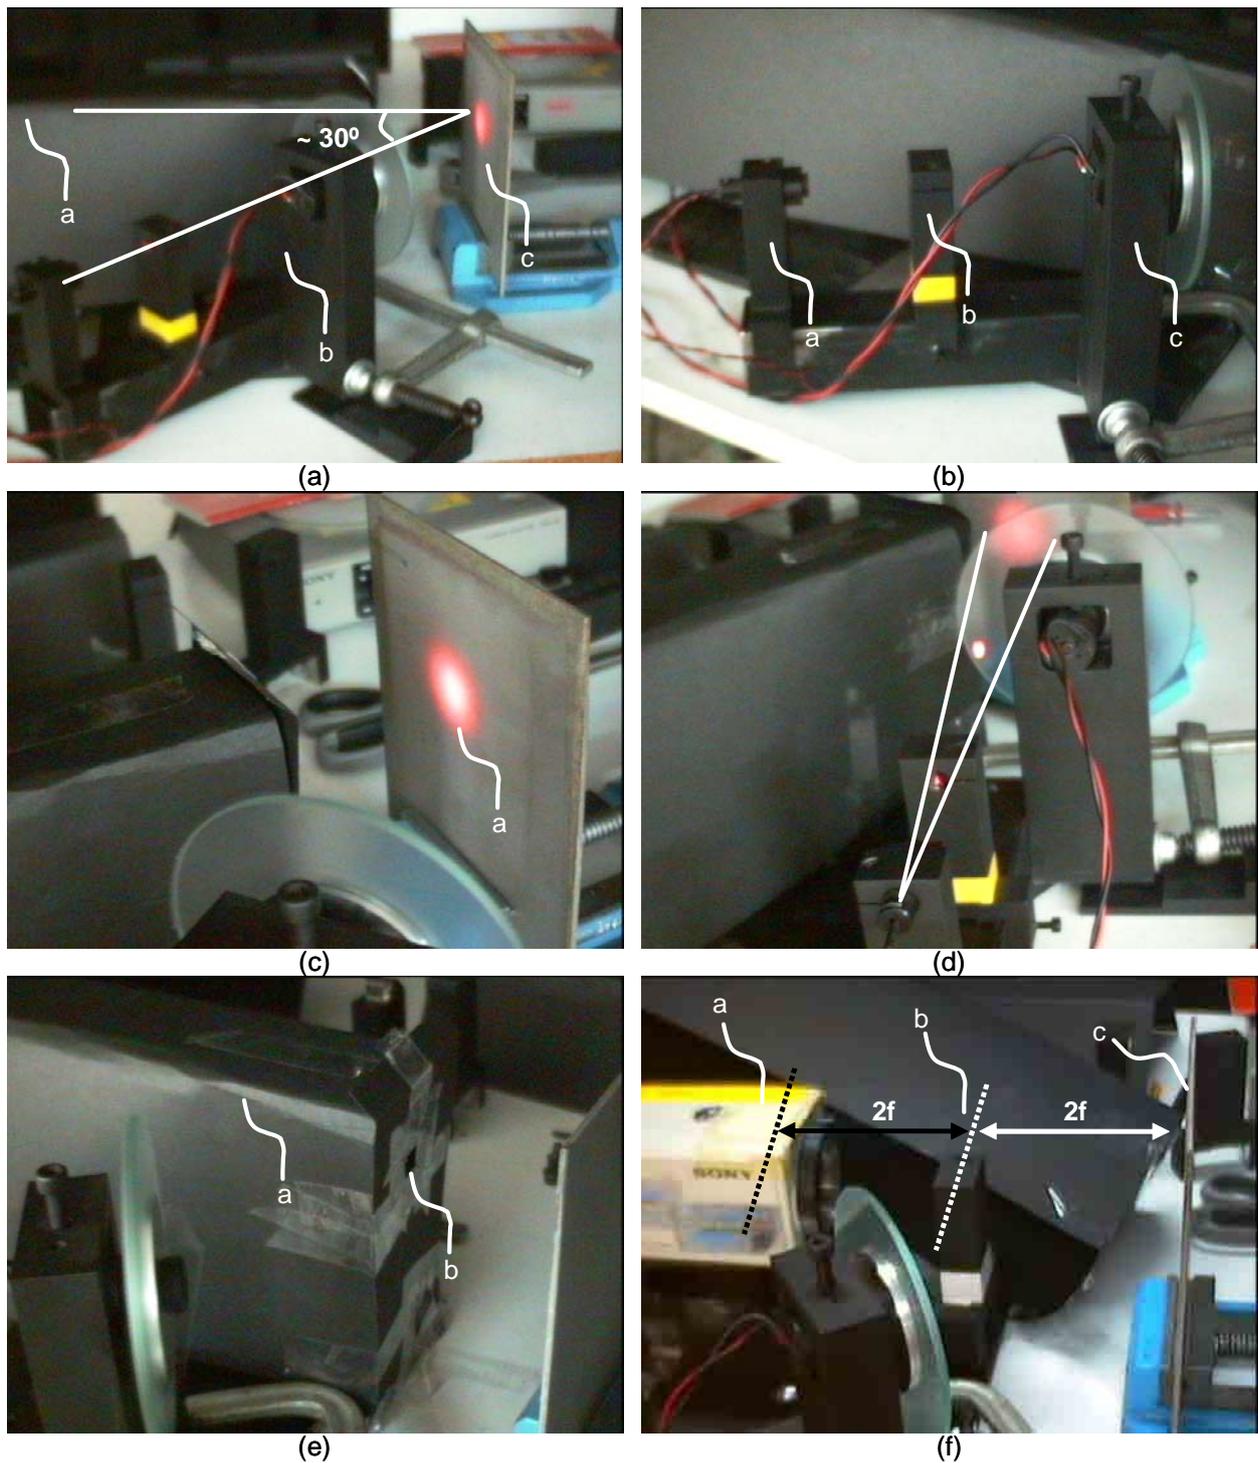
De esta forma sólo llega al sensor la luz reflejada en la plancha de acero inoxidable. Finalmente, en la figura 4.19f se destapa el protector negro y se observa la cámara Sony DXC-950P (fig. 4.19f<sup>a</sup>). También, se observa la lente de enfoque ( $f=55$  mm, fig. 4.19f<sup>b</sup>) y la plancha de acero inoxidable (fig. 4.19f<sup>c</sup>). La imagen se captura con magnificación  $M=1$ , por lo tanto, como se ve en la imagen la distancia entre el sensor CCD de la cámara y la lente de enfoque es 2 veces la distancia focal de la lente de enfoque, y la distancia entre la lente de enfoque y la plancha de acero también  $2f$ .

#### 4.4.2.2. Detección de cascarilla residual con láser rojo

Con el sistema de iluminación láser exterior se realizan dos experimentos. El primero con una lente de enfoque de distancia focal 160 mm y el segundo con lente de enfoque de distancia focal 55 mm. En ambos casos se utiliza un láser rojo de baja luminosidad. Primero se inspecciona con una lente que nos permite trabajar a la distancia de seguridad ( $\geq 300$  mm). Pero, al utilizar un láser rojo de baja luminosidad no es capaz de iluminar apropiadamente la plancha de acero inoxidable. Entonces, para demostrar la detección de defectos superficiales, se utiliza una lente de enfoque de 55 mm. Así, al acercar el láser a la plancha, el sistema es capaz de iluminar la plancha de acero inoxidable y detectar los defectos de cascarilla residual. En los resultados finales, el entorno-aplicación SIVA II soluciona este problema iluminando con un láser verde de alta luminosidad. Con este láser se resuelven los dos problemas: el de distancia de seguridad e iluminación apropiada a esta distancia.

- Experimento 1; Iluminación láser exterior; Lente de enfoque  $f = 160$  mm.

El experimento inspecciona la superficie de una plancha de acero inoxidable con defectos de cascarilla residual. La detección de los defectos superficiales se realiza mediante el sistema de iluminación láser exterior con una lente de enfoque de  $f=160$  mm. Los resultados no son satisfactorios debido a que la distancia entre la lente y la plancha de acero ( $2f = 320$ mm) es demasiado grande y el láser rojo es incapaz de iluminar de forma difusa la superficie a



**Figura 4.19:** (a) Sistema de iluminación láser exterior, (b) Detalle del módulo de iluminación láser, (c) Plancha de acero inoxidable iluminada con luz láser, (d) Detalle de apertura del haz láser, (e) Detalle de aislamiento del CCD, (f) Detalle de la lente de enfoque ( $f=55\text{mm}$ ) y cámara Sony DXC-950P

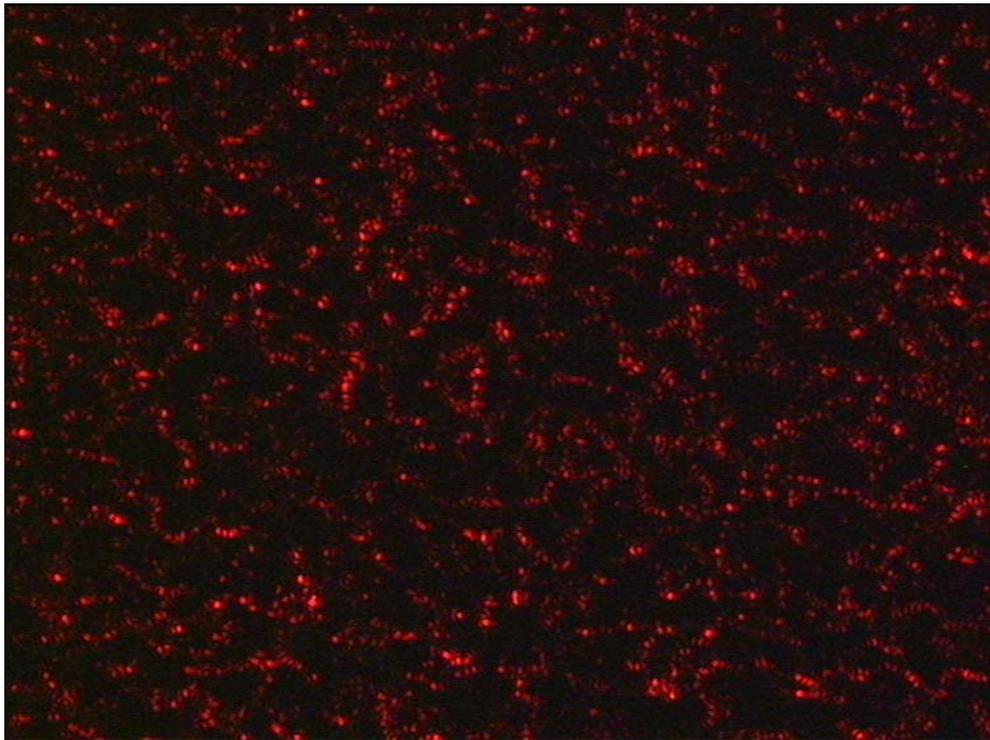
inspeccionar. A esta distancia el haz de luz reflejado en la superficie es débil y la imagen capturada por el sistema es muy oscura con algunos puntos brillantes debido a las regiones del acero más reflectantes. La figura 4.20a muestra una inspección con estas características. Por lo tanto, en dichas imágenes no se puede deducir si existe cascarilla y tampoco aparece ruido “speckle” debido al difusor giratorio. En el caso de retirar el difusor giratorio, el haz láser llega a la plancha de acero inoxidable con mayor intensidad, pero no difuso. Entonces, aparece ruido “speckle” como se observa en la figura 4.20b.

- Experimento 2; Iluminación láser exterior; Lente de enfoque  $f = 55$  mm.

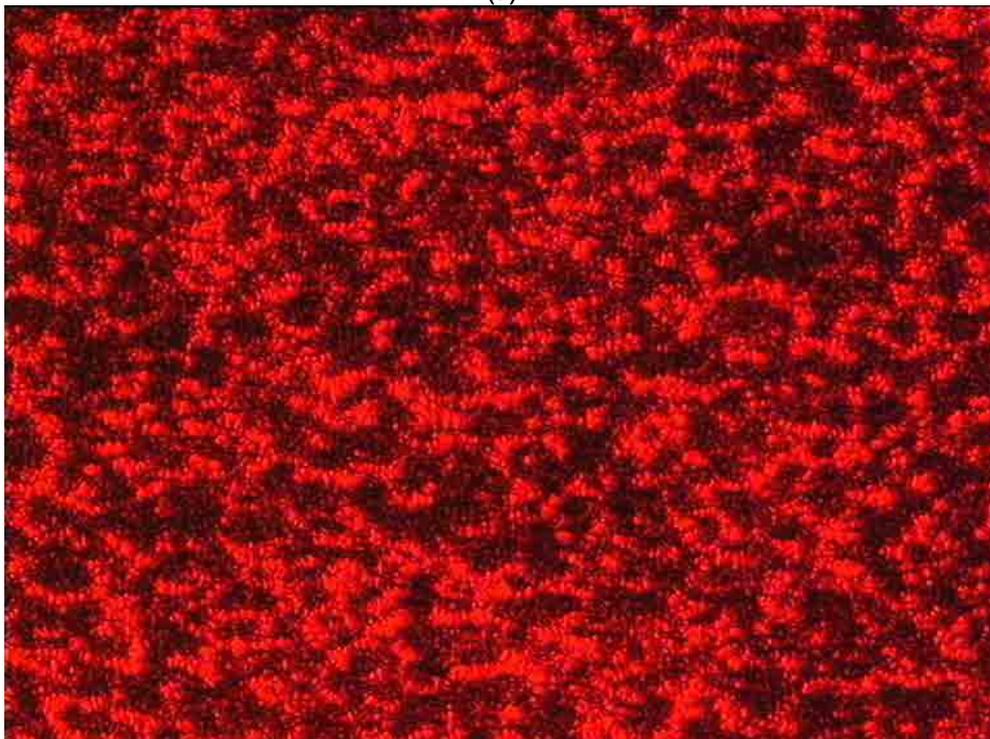
En este experimento se utiliza el mismo sistema que en el anterior, pero, se cambia la lente de enfoque por otra lente con menor distancia focal ( $f = 55$  mm). El objetivo es acercar la lente de enfoque a la plancha de acero inoxidable, para aumentar la iluminación difusa de la superficie a inspeccionar. Con esta configuración se consigue detectar los defectos de cascarilla residual en la plancha de acero inoxidable. La figura 4.21 muestra dos imágenes pertenecientes a la inspección de dos regiones distintas de la plancha de acero inoxidable, donde se aprecian claramente los defectos superficiales de cascarilla residual. Los resultados son satisfactorios, y el sistema viable y robusto para la industria.

## 4.5. Conclusiones del capítulo

Los dos sistemas de iluminación láser que se han diseñado e integrado para inspección de defectos superficiales aportan a la industria una solución viable, sencilla y robusta. La inspección industrial mediante iluminación láser difusa muestra resultados óptimos y soluciona el problema de inspección de diferentes superficies con el mismo sistema (e.j. acero inoxidable (como hemos visto en este capítulo), madera

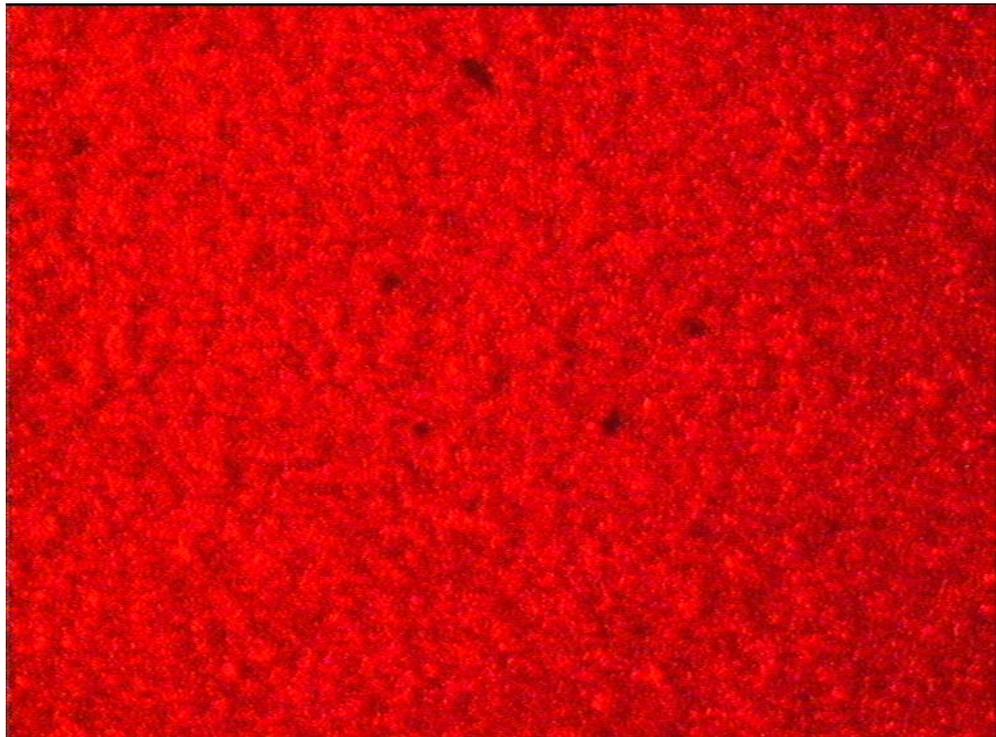


(a)

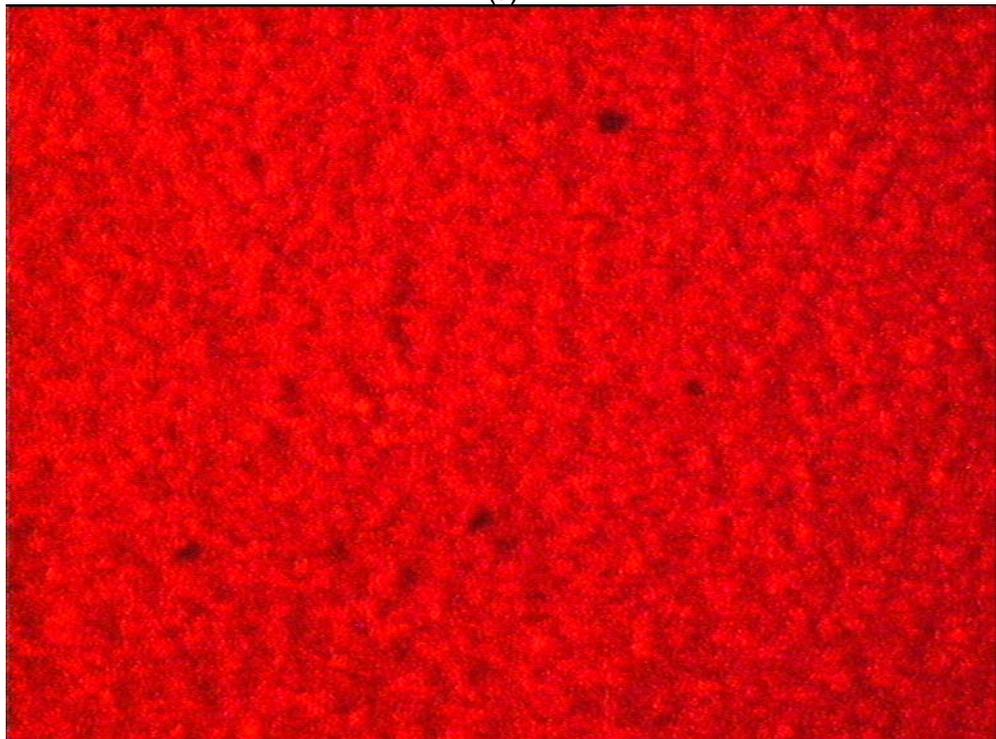


(b)

**Figura 4.20:** (a) Inspección de acero inoxidable mediante iluminación láser exterior y lente de  $f=160$  mm, (b) Aparición de “speckle” al quitar el difusor del sistema de iluminación



(a)



(b)

**Figura 4.21:** (a-b) Detección de defectos superficiales de cascarilla residual en una plancha de acero inoxidable, mediante iluminación láser exterior

(se ve en el último capítulo en el entorno-aplicación SIVA II), etc.). La iluminación láser es robusta, pero presenta algunos problemas que se han solucionado. Uno de los problemas es el ruido “speckle”, que se ha eliminado utilizando un difusor giratorio. Además, se ha diferenciado entre ruido “speckle” y manchas de cascarilla, y se han observado los patrones de interferencia generados por los elementos ópticos (difusor, cubo y lente de enfoque).

Por otro lado, los dos sistemas se han podido investigar debido al banco óptico diseñado y desarrollado.

Los resultados han sido satisfactorios tanto con iluminación láser coaxial como con iluminación láser exterior. En los dos casos se ha detectado el defecto de cascarilla residual en planchas de acero inoxidable. En el caso de inspección láser exterior también se han detectado defectos en madera, como se verá en el último capítulo.

En iluminación láser coaxial se ha utilizado un láser rojo y en los experimentos con iluminación láser exterior se han utilizado un láser rojo y otro verde de alta luminosidad.

# Capítulo 5

## Arquitectura Cognitiva ARDIS

Las arquitecturas cognitivas [Sun et al., 2006], [Nason & Laird, 2005], [Young, 2005], [Wang et al., 2004] son modelos basados en el conocimiento y sirven para solucionar tareas complejas. La inspección de superficies es la tarea compleja en la que se centra esta tesis y que, debido a la variabilidad del entorno de inspección requiere conocimiento del dominio para su solución. La arquitectura cognitiva ARDIS (Arquitectura Dinámica para Inspección Visual de Superficies en Tiempo-Real) es la propuesta para la solución de esta tarea compleja.

La arquitectura debe solucionar cada problema concreto de inspección de superficies, esto es, detectar distintos defectos o inspeccionar diferentes superficies. Para lograr este cometido, la arquitectura ARDIS se basa en la siguiente idea: **configurar en tiempo-real un sistema de inspección de superficies adaptado a cada tipo particular de material laminado y de defecto a inspeccionar.**

Debido al entorno en el que se desarrolla la tarea, al control y supervisión de calidad, al tipo de defecto a inspeccionar, etc., la configuración de un sistema de inspección de superficies es compleja y requiere un análisis detallado que en este trabajo se lleva a cabo siguiendo la metodología CommonKADS [Schreiber et al., 2000]. Inicialmente, se definen los tres términos principales relativos a la arquitectura ARDIS propuesta:

- El término *arquitectura*, para referirnos a un modelo que se descompone en distintos módulos funcionales.
- El término *dinámico*, para referirnos a que el sistema de inspección de superficies es variable en función de los requisitos de entorno, tiempo-real, control de calidad y técnicas de visión artificial, de la aplicación de inspección.
- El término *cognitiva*, porque analiza en el nivel del conocimiento el problema de inspección de defectos superficiales en materiales laminados.

La arquitectura propuesta permite utilizar conocimiento general de inspección de superficies (conocimiento de entorno, de calidad, de tiempo-real, etc.) para configurar un sistema de inspección de superficies específico que permite inspeccionar diferentes materiales laminados, como metal, papel, madera, plástico, textil, entre otros.

El sistema de inspección de superficies configurado por la arquitectura ARDIS está compuesto por un conjunto de componentes (elementos de diseño) y los parámetros de estos componentes ajustados en función del tipo de superficie inspeccionada. Por ejemplo, un componente puede ser el elemento físico de iluminación, que también está compuesto por sus propios componentes y sus parámetros.

## 5.1. Problemática de inspección de superficies

Actualmente, existen en el mercado sistemas de inspección de superficies convencionales, los cuales son difíciles de reutilizar debido a que fueron diseñados para una única aplicación de inspección de superficies. También, se pueden encontrar nuevos entornos de desarrollo de aplicaciones con asistentes para seleccionar manualmente el tipo de inspección (inspección de piezas, inspección 3D, etc.), estos son demasiado generales, poseen pocos parámetros de configuración y no permiten introducir conocimiento del dominio [ProVision, 2003], [NeuroCheck, 2006].

Tampoco permiten introducir conocimiento de inspección, punto clave en la configuración de un sistema de inspección. Por ejemplo, una variación normal en un entorno industrial de inspección de superficies que los sistemas actuales de inspección no tienen en cuenta son las variaciones del grosor del material laminado. En este caso, al variar el grosor, también varía la distancia entre la cámara y el material laminado, y la cámara puede quedarse fuera de foco con la consiguiente captura de imágenes desenfocadas (ver apéndice A, para una explicación completa).

Así pues, los sistemas convencionales actuales no permiten utilizar un sistema de inspección de superficies en dos aplicaciones diferentes, porque el sistema fue diseñado para una única aplicación específica. Y tampoco, están preparados para soportar cambios en la propia línea de producción. Esto implica un coste elevado, porque cada sistema de inspección hay que desarrollarlo de nuevo desde el principio.

La solución de este problema favorecerá la introducción de sistemas de inspección en la industria de materiales laminados, porque se podrán reutilizar de una aplicación a otra. Además, el tiempo de desarrollo se verá reducido debido a que únicamente será necesario volver a configurar el sistema de inspección para la nueva aplicación o el nuevo tipo de defecto en la propia línea de producción.

Por otro lado, esto también favorece a las pequeñas industrias donde actualmente no se instalan sistemas de inspección debido a su elevado coste y aún continúan realizando la inspección de superficies de forma manual.

Por tanto, la solución de este problema dinámico de inspección de superficies permitirá:

- Reutilizar los sistemas de inspección de superficies.
- Reducir costes de inspección.
- Reducir el tiempo de desarrollo.
- Reducir la inspección manual.

- Aumentar las exigencias de los controles de calidad.

## 5.2. Solución al problema

La solución del problema de inspección de superficies es la composición de un sistema de inspección de superficies que permita un control de calidad óptimo de la superficie. Con este objetivo, se diseña y desarrolla la arquitectura cognitiva ARDIS, donde se analiza el problema en el nivel del conocimiento del dominio.

Debido a la complejidad de la tarea dinámica de inspección de superficies, la arquitectura propuesta descompone la tarea en subtareas más sencillas hasta que se alcanza el nivel de las inferencias.

En los capítulos anteriores se ha adquirido el conocimiento del dominio de inspección de superficies mediante diversos experimentos. Esto ha permitido diferenciar las necesidades de entorno, de control de calidad, de tiempo-real y de técnicas de visión por computador. En concreto, los experimentos se centraron en la inspección de acero inoxidable para detectar y clasificar defectos superficiales de cascarilla residual. La descripción de este conocimiento se ha realizado en lenguaje natural. Esto ha favorecido la producción de “conocimiento de inspección” genérico que después manejará la arquitectura. Por ejemplo, conocimiento de tiempo-real para inspeccionar laminados a alta velocidad.

Así, la flexibilidad para adaptarse a diferentes superficies laminadas y sus defectos superficiales centra esta solución en el campo de los sistemas de inspección de superficies actuales. Por ejemplo, en una línea de inspección de superficie puede variar el tipo de material laminado, el tipo, la posición y la orientación del defecto superficial (por ejemplo, rayas o manchas), etc.

Por otro lado, en la arquitectura ARDIS, se intenta que la flexibilidad no resida sólo en el diseñador de la arquitectura, que puede adaptar un sistema a diferentes inspecciones de superficies, sino en la propia arquitectura. Así pues, la arquitectu-

ra se compone de diferentes etapas con unas estructuras que utilizan conocimiento genérico del dominio y permiten configurar un sistema para adaptarse a la inspección específica. Por ejemplo, en la etapa relativa a tiempo-real los componentes son configurados para un único sistema de inspección y si la superficie o el defecto varía, se configuran los componentes de nuevo. Esta flexibilidad de configuración de componentes por la arquitectura contiene la flexibilidad del diseñador.

### 5.2.1. Modelado siguiendo la metodología CommonKADS

El modelado de la arquitectura cognitiva ARDIS para inspección dinámica de superficies se lleva a cabo siguiendo la metodología CommonKADS [Schreiber et al., 2000]: se considera la tarea dinámica de inspección de superficies en tiempo-real de reconfiguración como una tarea compleja de “diseño-configuración”.

[Motta, 1999] distingue diferentes tipos de diseño. Dentro de estos, los problemas de diseño donde el conjunto de componentes de entrada es fijo se llaman problemas de diseño-configuración [Stefik, 1995]. Por ejemplo, en nuestro caso, el componente de entrada relativo a entorno {GananciaSensorCámara}<sup>1</sup> es fijo para todos los sistemas de inspección pero es necesario configurarlo para la inspección concreta, esto es, seleccionar el parámetro apropiado de este componente {GananciaSensorCámara={Automático, Manual, Mínimo, Máximo}}.

La arquitectura dinámica ARDIS está modelada con “Poseidon for UML” [Poseidon, 2006], que es una herramienta de modelado en UML sobre Java. El modelado nos permite visualizar y especificar la estructura de la arquitectura ARDIS. En el apéndice B y C, se recogen los diagramas de actividad y las clases utilizadas en el modelo de la arquitectura ARDIS.

---

<sup>1</sup>Los componentes del sistema de inspección de superficies se indican con llaves

### 5.3. Ontología de la tarea de inspección de superficies

A continuación se detalla el diccionario de términos de la ontología de la tarea compleja de *Diseño-Configuración-de-Inspección-de-Superficies*<sup>2</sup>, que se usarán a lo largo del capítulo:

- Configuración básica inicial o sistema básico inicial o esqueleto inicial: configuración compuesta por un conjunto de componentes mínimo. Es una configuración básica que sirve para inspeccionar mientras se reconfigura el sistema completo, y por otro lado, es la base para la extensión hacia el sistema completo.
- Extensión del esqueleto inicial o configuración extendida: extensión de la configuración básica inicial teniendo en cuenta por separado los requisitos de entorno, de tiempo-real, de control de calidad y de técnicas de visión por computador. Esto es, la extensión del esqueleto inicial se compone de: extensión de entorno, extensión de tiempo-real, extensión de control de calidad y extensión de técnicas de visión por computador.
- Configuración completa o configuración global o sistema completo o sistema configurado: es la configuración final del sistema de inspección que ha sido revisada en su totalidad.
- Reconfiguración: sucesivas configuraciones, si varía el material a inspeccionar o los objetivos de inspección (por ejemplo, el tipo de defecto, el tipo de calidad, etc.).
- Tiempo-real de reconfiguración del sistema de inspección: tiempo-real asociado a la tarea principal de la arquitectura ARDIS (*Diseño-Configuración-de-Inspección-de-Superficies*). Este tiempo-real se refiere al tiempo de que dispone

---

<sup>2</sup>Las tareas, subtareas e inferencias se indican con letra cursiva

una aplicación concreta para reconfigurar un sistema de inspección en una línea de inspección (éste varía según la aplicación de inspección de superficies).

- **Tiempo-real de inspección:** tiempo-real asociado a la propia inspección de la superficie específica, cuando el sistema configurado está en funcionamiento. Este tiempo-real se refiere al tiempo, que necesita una aplicación concreta para aplicar las técnicas de visión artificial a la imagen (éste varía, dentro de un cierto rango, según la aplicación de inspección de superficies). Éste rango se debe a que unas imágenes necesitan más o menos tiempo que otras para el procesado de la imagen. Para conseguir un tiempo-real de inspección variable en un cierto rango se utiliza un buffer.
- **“Diseñador de la arquitectura” o “usuario experto”:** son usuarios que poseen y pueden introducir tipos de conocimiento genérico del dominio de inspección de superficies que posteriormente utilizará la arquitectura, poseen todos los permisos. En el proceso de inspección son los encargados de crear y mantener la base de conocimiento que utiliza la arquitectura ARDIS.
- **“Encargado del sistema de inspección” o “inspector de la línea de producción”:** tiene permiso para especificar los requisitos del sistema de inspección de superficies específico y validar los resultados de inspección. En el proceso de inspección en la línea de producción su función es configurar el sistema. Posee el tipo de conocimiento relativo a la aplicación específica, por ejemplo, puede seleccionar si el defecto que se quiere inspeccionar en la línea de producción es circular o lineal, entre otros.
- **“Operario de inspección de la superficie”** es la persona que maneja el sistema de inspección en operación: sólo tiene permiso para validar los resultados de inspección de la superficie, obtenidos por el sistema configurado. El operario de inspección posee el tipo de conocimiento de inspección manual. Para validar los resultados del sistema configurado éste realiza una inspección manual.

## 5.4. Conocimiento genérico del dominio de inspección de superficies

El **conocimiento del dominio de inspección de superficies** integra diferentes tipos de conocimiento genérico, que son conocimiento de tiempo-real, de diagnóstico de calidad, de entorno y de técnicas de visión por computador.

La diferenciación de tipos de conocimiento permite particularizar el conocimiento utilizado en cada inferencia. Esto facilita la especificación de componentes y sus interacciones, como es el caso de las técnicas de visión por computador, las necesidades de control de calidad de la superficie a inspeccionar, etc. Un primer ejemplo se observa en las tablas 5.1 y 5.2 que muestran parte de dos tipos de conocimiento genérico (entorno y defecto superficial). En los siguientes apartados se detallan todos los tipos de conocimiento genérico que utiliza la arquitectura ARDIS. Además, de forma especial, el tipo de conocimiento genérico de defecto superficial se puede utilizar en toda la arquitectura.

De esta forma, se consigue una arquitectura que proporciona todas las funcionalidades necesarias para configurar un sistema de inspección de superficies completo (entorno, calidad, tiempo-real de inspección, técnicas de visión por computador, etc.). La arquitectura ARDIS está basada en conocimiento del dominio de inspección de superficies, diferenciado en tipos para cada inferencia.

El diseñador de la arquitectura y posteriormente el usuario experto se basan en estos tipos de conocimiento de inspección de superficies, para introducir el **conocimiento basado en reglas clásicas y/o borrosas que es utilizado dentro de la arquitectura ARDIS**. Es decir, los tipos de conocimiento del dominio de inspección de superficies se utilizan mediante reglas en ARDIS. Este conocimiento basado en reglas junto con los requisitos del sistema de inspección componen un sistema de inspección de superficie, y este sistema resuelve el problema de inspección de la superficie (detección y clasificación de los defectos superficiales y control de calidad de

la superficie inspeccionada). Las reglas borrosas se utilizan en el caso que exista ambigüedad y vaguedad, esto es, imprecisión al especificar un requisito del sistema por el inspector de línea (por ejemplo, [Velocidad de línea de producción]={0-10}m/seg Variable numérica => {baja, media, alta} Variable Abstracta B (Borrosa)).

TIPO DE CONOCIMIENTO DEL DOMINIO DE INSPECCIÓN DE SUPERFICIES: ENTORNO	
<b>Línea de producción</b>	
Velocidad línea producción	{baja, media, alta}
Variación subclases de material	{baja, media, alta}
Variación grosor del material	{baja, media, alta}
<b>Superficie del material laminado</b>	
Reflectancia	{Débil, Media, Fuerte}
Rugosidad	{Débil, Media, Fuerte}
Textura	{Débil, Media, Fuerte}

**Tabla 5.1:** Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): entorno; y sus valores posibles

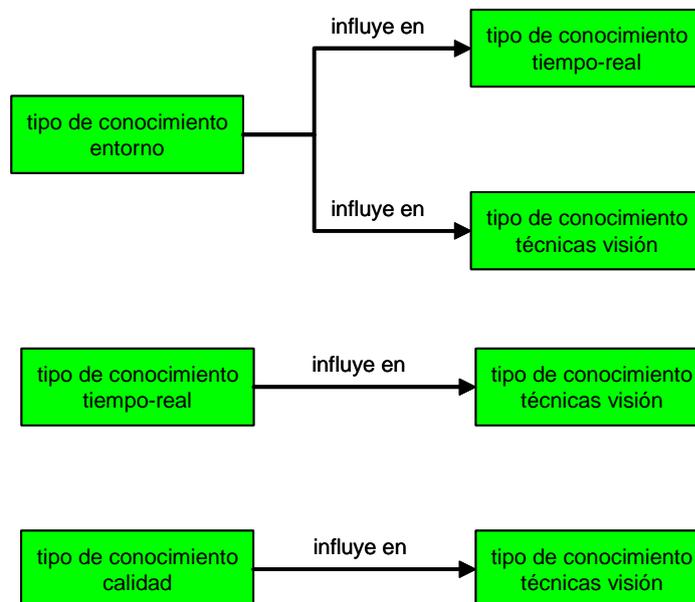
TIPO DE CONOCIMIENTO DEL DOMINIO DE INSPECCIÓN DE SUPERFICIES: DEFECTO SUPERFICIAL			
Variación forma	{Débil, Media, Fuerte}	Color y/o reflectancia	{Débil, Media, Fuerte}
Variación subclases de materiales	{Débil, Media, Fuerte}	Rugosidad	{Débil, Media, Fuerte}
Variación tamaño	{Débil, Media, Fuerte}	Textura	{Débil, Media, Fuerte}
<b>Forma exterior del defecto (contorno)</b>			
Carácter amorfo	{Débil, Medio, Fuerte}	Esquinas	{Débil, Media, Fuerte}
Inflexiones	{Débil, Media, Fuerte}		
<b>Área del defecto</b>			
Homogeneidad	{Débil, Media, Fuerte}	Textura	{Débil, Media, Fuerte}
Rugosidad	{Débil, Media, Fuerte}	Estructuración	{Débil, Media, Fuerte}

**Tabla 5.2:** Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): defecto superficial; y sus valores posibles

Así pues, el conocimiento está particionado por tipos de conocimiento orientados

a su uso en la arquitectura. Por ejemplo, la tabla 5.3<sup>3</sup> muestra parte del conocimiento genérico de calidad del dominio de inspección de superficies utilizado en las inferencias de la subtarea *Proponer-Extensión-Esqueleto-Diagnostico-Calidad*.

Por otro lado, la figura 5.1 muestra las relaciones que existen entre los tipos de conocimiento. Por ejemplo, el tipo de conocimiento de entorno se relaciona con el de tiempo-real, porque dependiendo de los elementos físicos de adquisición, iluminación, etc. estos influyen de diferente forma en el tiempo-real. Así pues, durante la configuración de un sistema de inspección, una vez configurado un componente de entorno, éste se tiene en cuenta en la configuración de los componentes de tiempo-real.



**Figura 5.1:** Relaciones entre tipos de conocimiento del dominio de inspección de superficies

Finalmente, el conocimiento del inspector de línea sobre el **dominio de la aplicación de inspección de superficies** es relevante en la configuración de un sistema de inspección de superficies, porque él selecciona los requisitos necesarios para

<sup>3</sup>(Tabla 5.3) Longitudinalmente => en la dirección de avance de la lámina

---

**CONOCIMIENTO GENÉRICO UTILIZADO EN LAS INFERENCIAS DE LA SUBTAREA Proponer-Extensión-Esqueleto-Diagnostico-Calidad (ver apéndice B)**


---

DetecciónAutomáticaDeDefecto={verdadero, falso}
AlmacenamientoDeInformación={verdadero, falso}
VerificarResultadosObtenidos={verdadero, falso}
ComplejidadControlDeCalidad={baja, media, alta}
InformaciónAdicionalInspectorDeLínea={verdadero, falso}
GravedadDefectoEnBaseAlaDensidadEncontrada={verdadero, falso}
GravedadDefectoEnBaseAlTamaño={verdadero, falso}
CriteriosDeCalidadEstablecidos={verdadero, falso}
FacilidadMantenimientoCalidad={baja, media, alta}
ViabilidadEconómicaInstalación={baja, media, alta}
ViabilidadEconómicaMantenimiento={baja, media, alta}
PorcentajeDefectoEnZonaInspeccionada={verdadero, falso}
EstadísticasDelDefecto={NúmeroDeDefectosPorUnidadDeSuperficie, TamañoMedioDefecto, DistribuciónDefecto}
TasaDeError={alta, media, baja}
TipoError={FalsoPositivo, FalsoNegativo}
ControlCalidadSuperficie={aceptable, inaceptable}
PrecisiónDelSistema={baja, media, alta}
TasaRendimiento(ÁreaInspeccionadaPorMinuto)={baja, media, alta}
CircunstanciasExtraordinarias={Soldaduras, ManchasAceite, ManchasAgua}
RangoDeCalidadClasificadoPorLosInspectoresParaPrimeraCalidad={pequeño, medio, grande}
RangoDeCalidadClasificadoPorLosInspectoresParaSegundaCalidad={pequeño, medio, grande}
MargenEnLaProporciónDeSuperficieManchadaPromedioEntrePrimeraYsegundaCalidad = {pequeño, medio, grande}
MaterialDePrimeraCalidad={verdadero, falso}
MaterialDeSegundaCalidad={verdadero, falso}
ProporciónDePíxelesConDefectos={baja, media, alta}
PromedioDePíxelesConDefectos={baja, media, alta}
ControlDeCalidadMínimo={1fps, 5fps, 10fps}
ControlDeCalidadMínimoSuficienteParaEstimarCalidad={verdadero, falso}
LaCalidadDelLaminadoCambiaLongitudinalmente <sup>6</sup> ={rápido, despacio}
LaEstimaciónDeCalidadPuedeHacerseAintervalosEspaciales={menosDeUnmetro, un metro, másDeUnMetro}

---

**Tabla 5.3:** Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea Proponer-Extensión-Esqueleto-Diagnostico-Calidad (ver apéndice B)

la configuración del sistema. Por ejemplo, en el caso de inspección de microdefectos de cascarilla residual, el inspector de línea puede especificar el tamaño del defecto superficial a inspeccionar.

## 5.5. Tarea dinámica de inspección de superficies como tarea de diseño-configuración

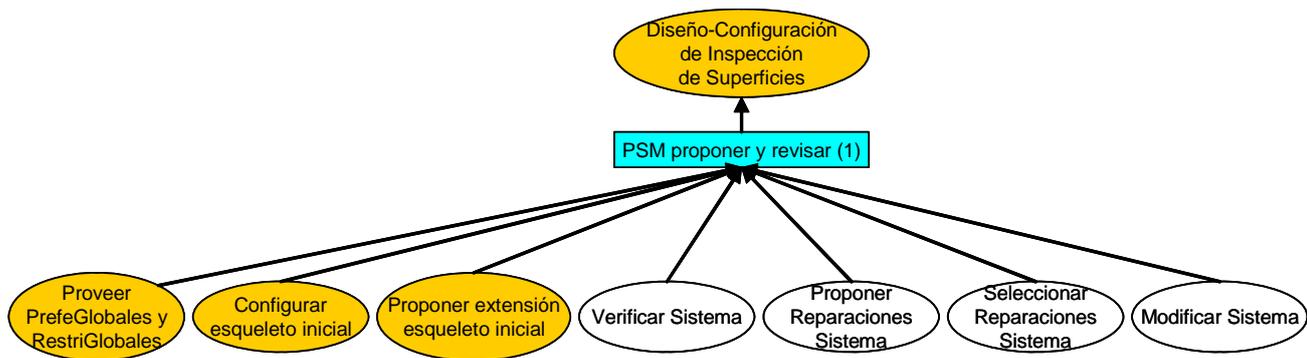
La tarea *Diseño-Configuración-de-Inspección-de-Superficies* se ha descompuesto en dos subtareas y una inferencia principales: *Configurar-esqueleto-inicial*, *Proponer-extensión-esqueleto-inicial* y *Verificar-Sistema*. Esto ha permitido abordar la solución de la tarea compleja de diseño-configuración en tres etapas.

La estructura de la solución de la tarea se basa, principalmente, en los requisitos del sistema de inspección y el conocimiento genérico del dominio de inspección de superficies. Esta estrategia se ha elegido por tratarse de una tarea de diseño-configuración. Así pues, los requisitos llegan a las subtareas necesarias de cada etapa, desde las subtareas relacionadas con la etapa de esqueleto inicial hasta las subtareas de la etapa de extensión del esqueleto inicial. Esto es una ventaja, porque en el caso de que varíe la aplicación de inspección (material laminado, defectos, entorno, necesidades de calidad, etc.), sólo es necesario introducir los nuevos requisitos y se configura un nuevo sistema de inspección de superficies.

En el apéndice B se pueden observar detalladamente todos los métodos y en el apéndice C, los diagramas de clases del conocimiento del dominio orientado a la aplicación de inspección de superficies. En los siguientes apartados, se entra en detalle en la estructura de tareas y subtareas que forman la arquitectura ARDIS y los métodos que resuelven estas tareas y subtareas.

### 5.5.1. Tarea de Diseño-Configuración de Inspección de Superficies

Nuestra propuesta descompone la tarea dinámica de inspección de superficies en tres etapas principales y sus correspondientes subtareas hasta que se alcanza el nivel primitivo de inferencias. La figura 5.2 muestra la descomposición jerárquica de la tarea de *Diseño-Configuración-de-Inspección-de-Superficies*. Éste es el diagrama principal de subtareas e inferencias que solucionan el problema de inspección de superficies. Las elipses coloreadas simbolizan las tareas y subtareas, y las elipses sin colorear representan las inferencias. La descomposición de la tarea de *Diseño-Configuración-de-Inspección-de-Superficies* se basa en las ideas siguientes:



**Figura 5.2:** Descomposición jerárquica de la tarea de Diseño-Configuración de Inspección de Superficies

- La tarea global *Diseño-Configuración-de-Inspección-de-Superficies* se descompone mediante el PSM `proponer-y-revisar(1)`<sup>4 5</sup>, que propone una única configuración completa del sistema basándose en el esqueleto inicial del sistema y revisa el resultado propuesto para la aplicación específica. De esta forma, dado un conjunto predefinido de componentes, se ensamblan de forma que sa-

<sup>4</sup>Método `proponer-y-revisar (1)`, para la tarea de *Diseño-Configuración-de-Inspección-de-Superficies*

<sup>5</sup>Los PSMs se indican con tipo de letra courier

tisfacen las preferencias y obedecen las restricciones. Por lo tanto, usamos una estructura de una tarea de síntesis que está basada en requisitos externos (requisitos fuertes (restricciones) y débiles (preferencias)) seleccionados por el inspector de línea o usuario experto. La propuesta está formada por:

- Primera etapa. La subtarea *Configurar-esqueleto-inicial* que se descompone mediante el PSM *proponer-y-revisar(2)*<sup>6</sup> y configura el esqueleto inicial extendiendo el esqueleto inicial actual de forma incremental. Aquí, se propone un componente, a continuación se añade al esqueleto inicial actual y posteriormente se revisa el esqueleto inicial actual. Este método propone y revisa el esqueleto inicial componente a componente, a diferencia del método anterior *proponer-y-revisar(1)* que propone el sistema completo y después lo revisa. El objetivo es proponer y revisar una configuración básica inicial, y sirve para disponer de una solución inicial que además es la base para la siguiente subtarea. Esta subtarea inicial se debe a dos razones: primero, todo sistema necesita una inicialización y, segundo, forma parte de la estrategia de tiempo-real de reconfiguración de la arquitectura ARDIS, ya que permite configurar rápidamente un sistema básico de inspección mientras se configura el sistema completo con la siguiente subtarea.
- Segunda etapa. La subtarea *Proponer-extensión-esqueleto-inicial* que se descompone utilizando el método *Descomponer-Configuración-En-Etapas* para permitir configurar cada subetapa de extensión (entorno, tiempo-real, etc.) por separado. El objetivo es extender el sistema básico inicial teniendo en cuenta las necesidades de entorno, tiempo-real, control de calidad y técnicas de visión por computador del sistema, y sirve para obtener la configuración extendida del sistema. La subtarea *Proveer-Preferencias-Globales-*

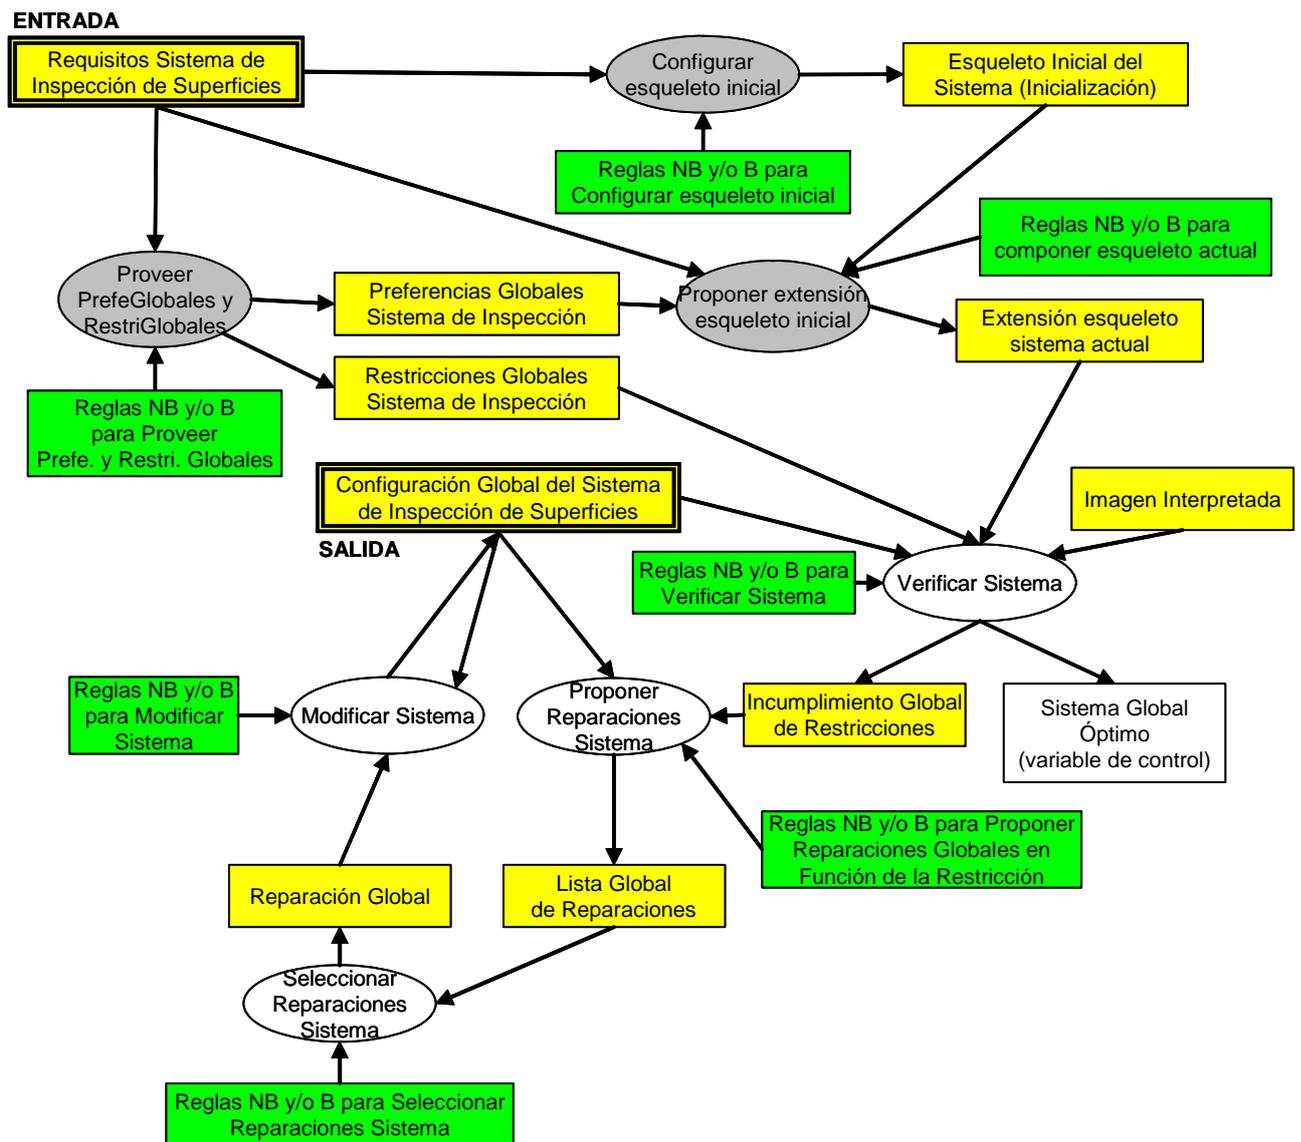
---

<sup>6</sup>Método *proponer-y-revisar (2)*, para las subtareas *Configurar-esqueleto-inicial*, *Proponer-Extensión-Esqueleto-Entorno* y *Proponer-Extensión-Esqueleto-Tiempo-Real*

*y-RestriGlobales* provee las preferencias globales para componer las cuatro extensiones.

- Tercera etapa. La revisión de la propuesta anterior se lleva a cabo mediante las siguientes cuatro inferencias: *Verificar-Sistema*, *Proponer-Reparaciones-Sistema*, *Seleccionar-Reparaciones-Sistema*, *Modificar-Sistema*, y sirve para revisar la configuración extendida y obtener la configuración global del sistema de inspección de superficies. La subtarea *Proveer-PreferenciasGlobales- y-RestriGlobales* provee las restricciones globales que permiten verificar la configuración extendida propuesta.

La figura 5.3 muestra el diagrama de subtareas e inferencias del método *Proponer-y-Revisar(1)* utilizado para la solución de la tarea de *Diseño-Configuración de Inspección de Superficies*. Se ha elegido este método porque permite proponer un conjunto de componentes que configuran el sistema de inspección y posteriormente verificarlo. Esta estrategia favorece una solución robusta, necesaria en el entorno industrial.



**Figura 5.3:** Diagrama de subtareas e inferencias del PSM Proponer-y-Revisar(1) para la tarea de Diseño-Configuración de Inspección de Superficies

Los requisitos del sistema de inspección de superficies (la tabla 5.4 muestra los requisitos globales) y la imagen interpretada son los roles dinámicos de entrada que se instancian para cada aplicación específica. Estos, junto con los roles estáticos de conocimiento genérico de inspección de superficies ('Reglas NBy/oB para Con-

---

Requisitos del sistema de inspección: <b>Requisitos Globales</b>
ConfiguraciónReconfigurable={si, no}
ConfiguraciónEntorno={si, no}
ConfiguraciónTiempo-Real={si, no}
ConfiguraciónControl Calidad={si, no}
PosibilidadDeExtensión DeConfiguración={si, no}
Prioridad Extensión Configuración={Entorno, Tiempo-real, Calidad}
Tipo de Superficie de Inspección={Acero inoxidable, Acero, Madera, Cerámica, Papel, Plastico, Textil, Marmol}

---

**Tabla 5.4:** Requisitos globales para la configuración del sistema de inspección de la superficie específica y sus valores posibles

figurar Esqueleto Inicial<sup>7</sup> y ‘Reglas NBy/oB para componer esqueleto actual’), resuelven primero la subtarea *Configurar-esqueleto-inicial* y seguidamente la subtarea *Proponer-extensión-esqueleto-inicial*. Con la solución de estas dos subtareamos el «Esqueleto Inicial del Sistema (Inicialización)»<sup>8</sup> y la «Extensión esqueleto sistema actual».

El rol dinámico «Configuración Global del Sistema de Inspección de Superficies», contiene la solución actual del problema dinámico de inspección de superficies. La solución se forma reuniendo todas las extensiones de esqueleto propuestas (ver estructura de control, apéndice D). Así, se consigue la configuración de determinados componentes del sistema de inspección y el ajuste de sus parámetros, incluidos los componentes de visión por computador formados por las técnicas de visión por computador que segmentan, clasifican, etc. los defectos superficiales.

Finalmente, la inferencia *Verificar-Sistema* revisa la configuración extendida (primera verificación) o configuración actual del sistema (sucesivas verificaciones), a partir del rol dinámico «Restricciones Globales Sistema de Inspección» ayudada por los

---

<sup>7</sup>Los roles estáticos se indican con comillas simples en el texto y en las figuras con color verde.

NB=No Borrosas

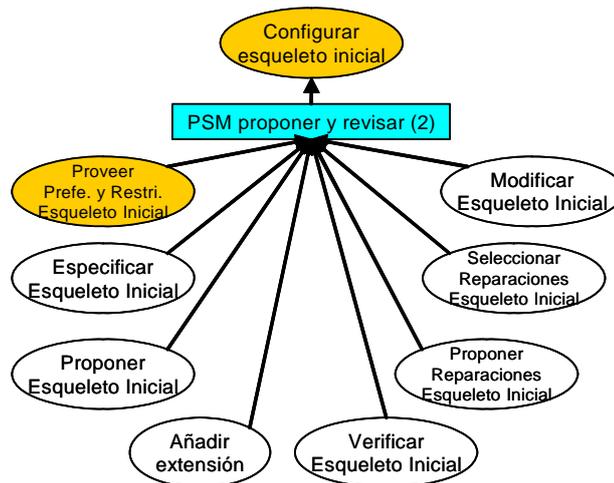
B=Borrosas

<sup>8</sup>Los roles dinámicos se indican con comillas angulares en el texto y en las figuras con color amarillo.

resultados de interpretación de la imagen que se obtienen en la subtarea *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*. Esta estrategia añade fiabilidad al resultado de la inferencia, porque ésta verifica la configuración extendida del sistema mediante un resultado propio de la configuración extendida previo a la revisión. Por ejemplo, si el sistema se ha configurado para inspección de defectos oscuros y la interpretación de la imagen es que sólo hay defectos claros o que el menor nivel de gris es claro, ayuda a modificar la configuración extendida (este ejemplo de interpretación se realizaría con un conjunto amplio de imágenes). El conocimiento del dominio de inspección de superficies para esta inferencia, se encuentra encapsulado en el rol estático ‘Reglas NBy/oB para verificar sistema’ y se encarga de comprobar si la configuración actual del sistema es consistente o necesita revisión. En caso de que la verificación falle, el rol dinámico «Incumplimiento Global de Restricciones» recoge la lista de restricciones incumplidas. Pero, si no se infringen las restricciones, la verificación es positiva y la variable de control “Sistema Global Óptimo” finaliza la configuración del sistema de inspección de superficies (ver estructura de control, apéndice D). Continuando con el caso de incumplimiento de alguna restricción, la siguiente inferencia es *Proponer-Reparaciones-Sistema*, donde, a partir de la configuración actual del sistema y el rol estático ‘Reglas NBy/oB para proponer reparaciones globales en función de la restricción’, se asocia la restricción incumplida a una o varias reparaciones del sistema actual. En la situación de producirse varias reparaciones, se presenta una lista ordenada de posibles reparaciones. La siguiente inferencia *Seleccionar-Reparaciones-Sistema* simplemente selecciona la primera reparación de la lista. Finalmente, la inferencia *Modificar-Sistema* aplica la reparación global seleccionada a la configuración actual del sistema. Este proceso se repite hasta que se cumplen todas las restricciones globales del sistema de inspección.

### 5.5.2. Subtarea Configurar Esqueleto Inicial

La subtarea *Configurar-esqueleto-inicial* proporciona una configuración rápida inicial para un sistema de inspección de una superficie. La descomposición jerárquica de la subtarea se puede observar en la figura 5.4.



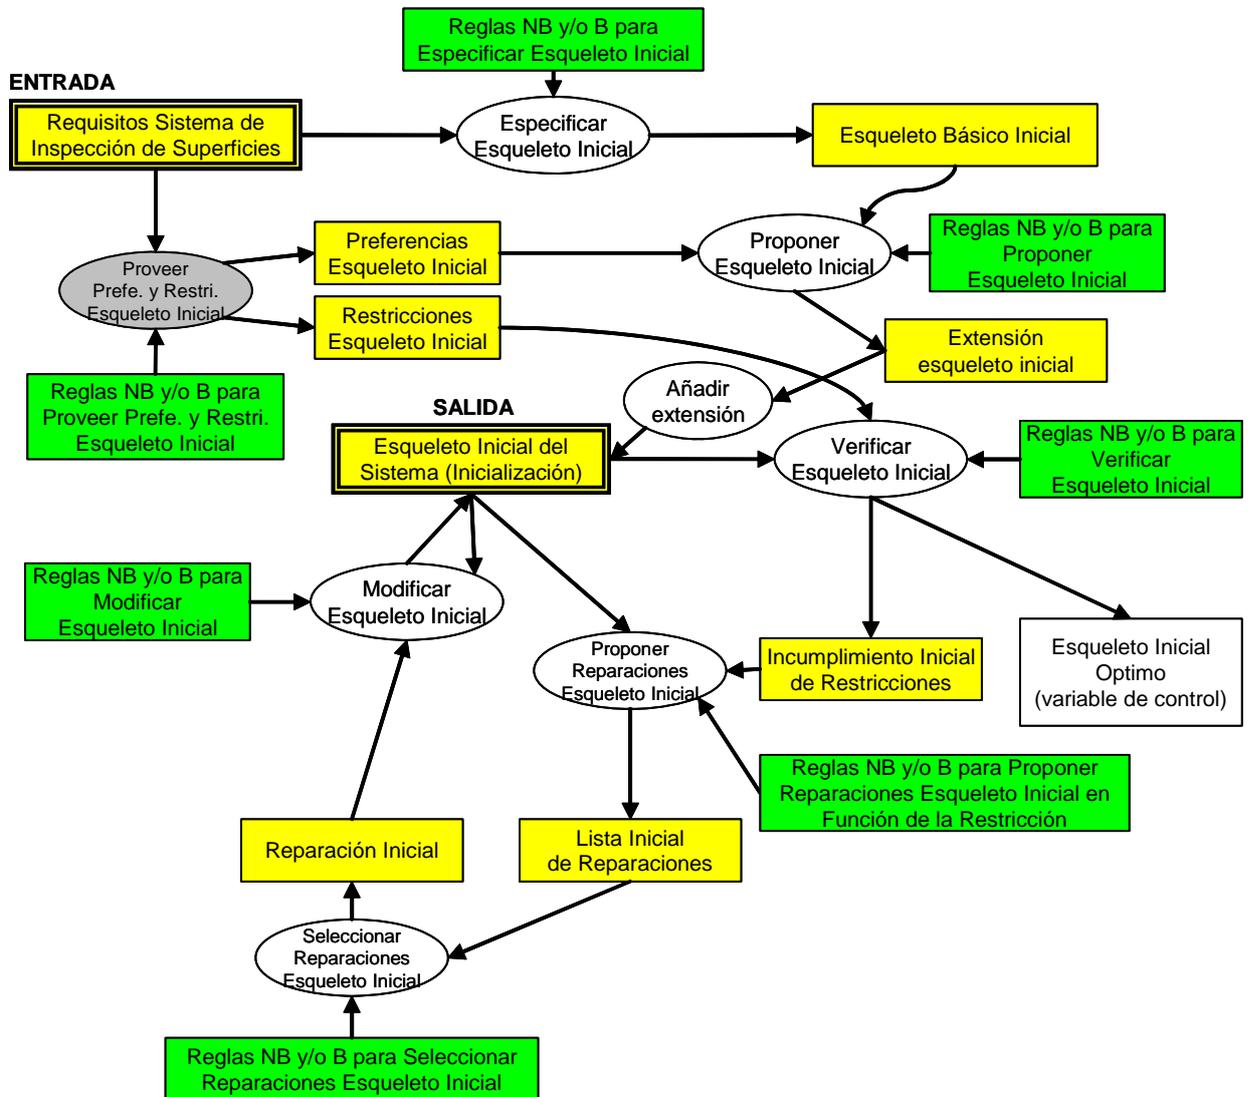
**Figura 5.4:** Descomposición jerárquica de la subtarea Configurar esqueleto inicial

La figura 5.5 presenta el diagrama de subtareas e inferencias del método *Proponer-y-Revisar(2)* para la subtarea *Configurar-esqueleto-inicial*. La función de esta subtarea de inicialización es configurar el esqueleto inicial, es decir, los componentes básicos del sistema de inspección. Por otro lado, el esqueleto inicial es la base para las siguientes extensiones relativas al entorno, tiempo-real, etc.

Este sistema inicial se configura mediante los requisitos iniciales seleccionados por el inspector de línea, tales como, [Configuración Estándar]<sup>9</sup>, [Configuración Robusta], [Información Instantánea al Inspector (supervisión)], etc. (tabla 5.5). Los requisitos iniciales proveen las preferencias y restricciones del esqueleto inicial. El esqueleto inicial satisface las «preferencias del esqueleto inicial» y obedece las «restricciones del esqueleto inicial». El resultado es un sistema básico para detección de

<sup>9</sup>Los requisitos del sistema de inspección y las variables se indican con corchetes

defectos en la superficie y se compone de los elementos de diseño o componentes de adquisición de imagen, de segmentación y de estadísticas de los defectos.



**Figura 5.5:** Diagrama de subtarefas e inferencias del PSM Proponer-y-Revisar (2) para la subtarea Configurar esqueleto inicial

Esta configuración inicial sencilla permite al sistema comenzar a inspeccionar mientras se configura el sistema completo. En el caso de reconfiguración del sistema de inspección en tiempo real de la aplicación, la arquitectura puede configurar rápidamente un esqueleto inicial nuevo mientras se configura el nuevo sistema completo

---

Requisitos del sistema de inspección: <b>Requisitos iniciales</b>
---

---

ConfiguraciónVersátil={si, no}
ConfiguraciónEstándar={si, no}
ConfiguraciónGlobal={si, no}
ConfiguraciónRobusta={si, no}
InspecciónSuperficialDeMaterialesLaminados={si, no}
PosibilidadDeReutilizaciónDeConfiguración={si, no}
EncuestaConElExperto={si, no}
VerificaciónInspector={si, no}
InformaciónInstantáneaAlInspector(supervisión)={si, no}
Tipo de Superficie de Inspección={Acero inoxidable, Acero, Madera, Cerámica, Papel, Plastico, Textil, Marmol}

---

**Tabla 5.5:** Requisitos iniciales para la configuración del sistema de inspección de la superficie específica y sus valores posibles

sin necesidad de parar la inspección en la línea de producción. Una reconfiguración en tiempo real de la aplicación puede ser debida, por ejemplo, a la necesidad de inspeccionar otro tipo de defecto en el mismo material laminado.

El método **Proponer-y-Revisar(2)** primero propone un componente del esqueleto inicial del sistema y posteriormente lo revisa, esto es, se configura el esqueleto inicial extendiendo el esqueleto inicial actual de forma incremental. Obsérvese que es necesario revisarlo porque el esqueleto inicial que, tiene entidad propia, es un pequeño sistema de inspección configurado con los componentes básicos para inspección en la línea de producción. Los componentes y parámetros básicos del esqueleto inicial son los elementos de adquisición de imagen, las técnicas de mejora de la imagen (por ejemplo, transformaciones básicas de los niveles de gris, técnicas de procesado de histograma, filtrado, etc.) y de segmentación de la imagen (por ejemplo, detección de discontinuidades, métodos de umbralización, etc.).

El conocimiento genérico del dominio de inspección de superficies se utiliza en cada uno de los siguientes roles estáticos (figura 5.5): ‘Reglas NBy/oB para Configurar Esqueleto Inicial’, ‘Reglas NBy/oB para proveer preferencias restricciones esqueleto inicial’, ‘Reglas NBy/oB para proponer esqueleto inicial’, ‘Reglas NBy/oB para veri-

ficar esqueleto inicial', 'Reglas NBy/oB para proponer reparaciones esqueleto inicial en función de la restricción', 'Reglas NBy/oB para seleccionar reparaciones esqueleto inicial' y 'Reglas NBy/oB para modificar esqueleto inicial'. La tabla 5.6 muestra un ejemplo de este tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de esta subtask *Configurar-esqueleto-inicial*.

A continuación se muestra un pequeño ejemplo de la base de conocimiento que utiliza el rol estático 'Reglas NBy/oB para proveer preferencias restricciones esqueleto inicial' (haciendo uso del requisito [NB\_TipoDeSuperficieInspección] que es un requisito inicial y global (tabla 5.5)):

Preferencias:

SI NB\_TipoDeSuperficieInspección es AceroInoxidable ENTONCES Prefe.Defecto es ReflectanciaDelDefecto

SI NB\_TipoDeSuperficieInspección es Madera ENTONCES Prefe.Defecto es FormaDelDefecto

SI NB\_ConfiguraciónRobusta es Verdadero Y Prefe.Defecto es ReflectanciaDelDefecto ENTONCES Prefe.PreprocesadoImagen es Verdadero

Restricciones:

SI NB\_TipoDeSuperficieInspección es AceroInoxidable ENTONCES B\_Restri.MinNivelDeGrisImagenCalculadoImagen es bajo

SI NB\_TipoDeSuperficieInspección es AceroInoxidable ENTONCES B\_Restri.MinNivelDeGrisSensorFotoelectricoCalculado es bajo

SI NB\_TipoDeSuperficieInspección es Madera ENTONCES B\_Restri.ÁreaMínimaDelDefectoCalculadoImagen es media

SI NB\_ConfiguraciónRobusta es Verdadero Y NB\_ConfiguraciónGlobal es Verdadero ENTONCES Restri.PreprocesadoImagen es Falso

### 5.5.3. Subtask Proponer extensión esqueleto inicial

La subtask *Proponer-extensión-esqueleto-inicial* se encarga de extender la configuración inicial propuesta en la subtask anterior *Configurar-esqueleto-inicial*.

La subtask *Proponer-extensión-esqueleto-inicial* compone un esqueleto teniendo en cuenta los requisitos globales, de entorno, de tiempo-real, de calidad y de

---

**CONOCIMIENTO GENÉRICO UTILIZADO EN LAS INFERENCIAS DE LA SUBTAREA *Configurar-esqueleto-inicial* (figura 5.5)**

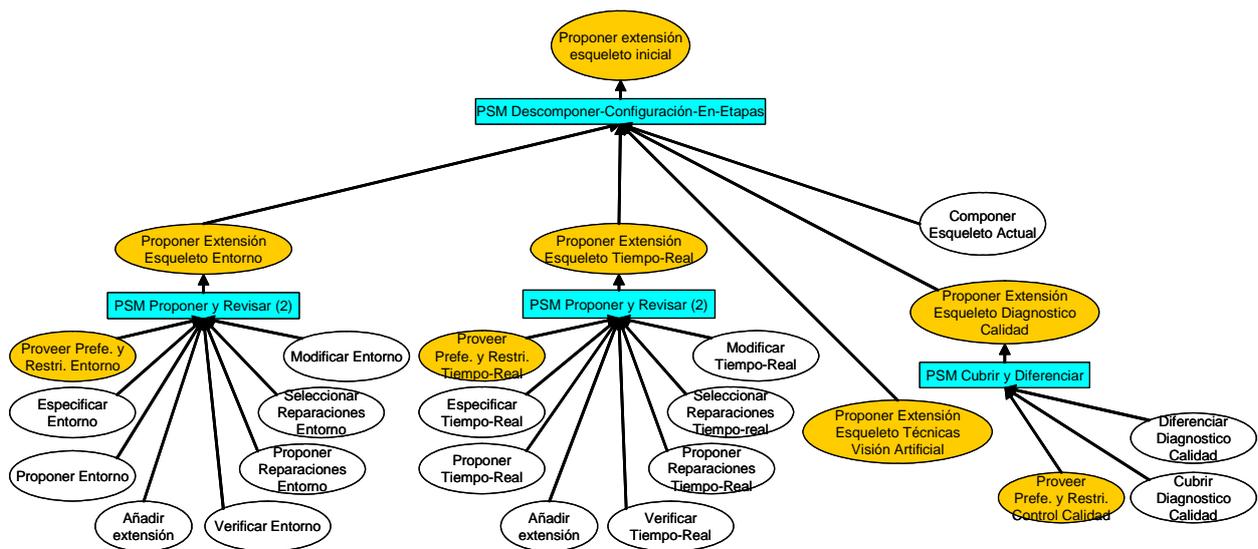

---

DefectoSuperficial={verdadero, falso}
CanalImagen={rojo, verde, azul}
RecortarBordeImagen={bajo, medio, alto}
TécnicaSegmentación={Umbralización, DetecciónDeDiscontinuidades}
UmbralEstimadoSegmentaciónImagen={Manual, MinNivelDeGrisImagen, CalculoDeUmbralAutomático}
TipoFiltro={Wiener, Unsharp}
TipoVecindad={Vecindad8, Vecindad4}
ImagenFiltradaMasMedia={verdadero, falso}
UmbralEstimadoSegmentaciónSensorFoto={MinNivelDeGrisSensorFoto, CalculoDeUmbralAutomático}
OperadorDetecciónDeDiscontinuidades={OperadorDeSobel, OperadorDePrewitt}
UmbralMétodoSobel={Manual, SelecciónAutomáticaMatlab}
Prefe.Defecto={ ReflectanciaDelDefecto, FormaDelDefecto}
Prefe.PreprocesadoImagen={verdadero, falso}
Prefe.TipoFiltro={FiltroPasoBajo, FiltroPasoAlto}
Restri.B_MinNivelDeGrisImagenCalculadoImagen={bajo, medio, alto}
Restri.B_MinNivelDeGrisSensorFotoelectricoCalculado={bajo, medio, alto}
B_ÁreaMínimaDelDefectoCalculadoImagen={pequeña, media, alta}
Restri.PreprocesadoImagen={verdadero, falso}
Restri.AplicarFiltro={verdadero, falso}
ConfiguraciónEsqueletoInicialSistema={ OKConfiguración, FALLOConfiguración}
IncumplimientoInicialRestricciones={ Restricción1, ..., RestricciónN}
RestricciónUsada1={ verdadero, falso}
RestricciónUsadaN={ verdadero, falso}

---

**Tabla 5.6:** Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea *Configurar-esqueleto-inicial* (figura 5.5)

técnicas de visión por computador seleccionados por el inspector de línea. La etapa posee conexión con el inspector de línea (selección de requisitos) o usuario experto (introducción de conocimiento a la arquitectura) en la parte de alto nivel y conexión directa con la imagen capturada por el sistema de inspección a través de la sub-tarea *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*. La descomposición de la sub-tarea *Proponer-extensión-esqueleto-inicial* se puede observar en la figura 5.6 donde se refleja la estructura de subtareas e inferencias. En el diagrama se muestran desarrolladas las subtareas, excepto *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial* que requiere una explicación más detallada debido a que conecta con la imagen adquirida y en ella se clasifican o seleccionan las técnicas apropiadas de segmentación, representación, descripción, etc. para la superficie específica a inspeccionar.

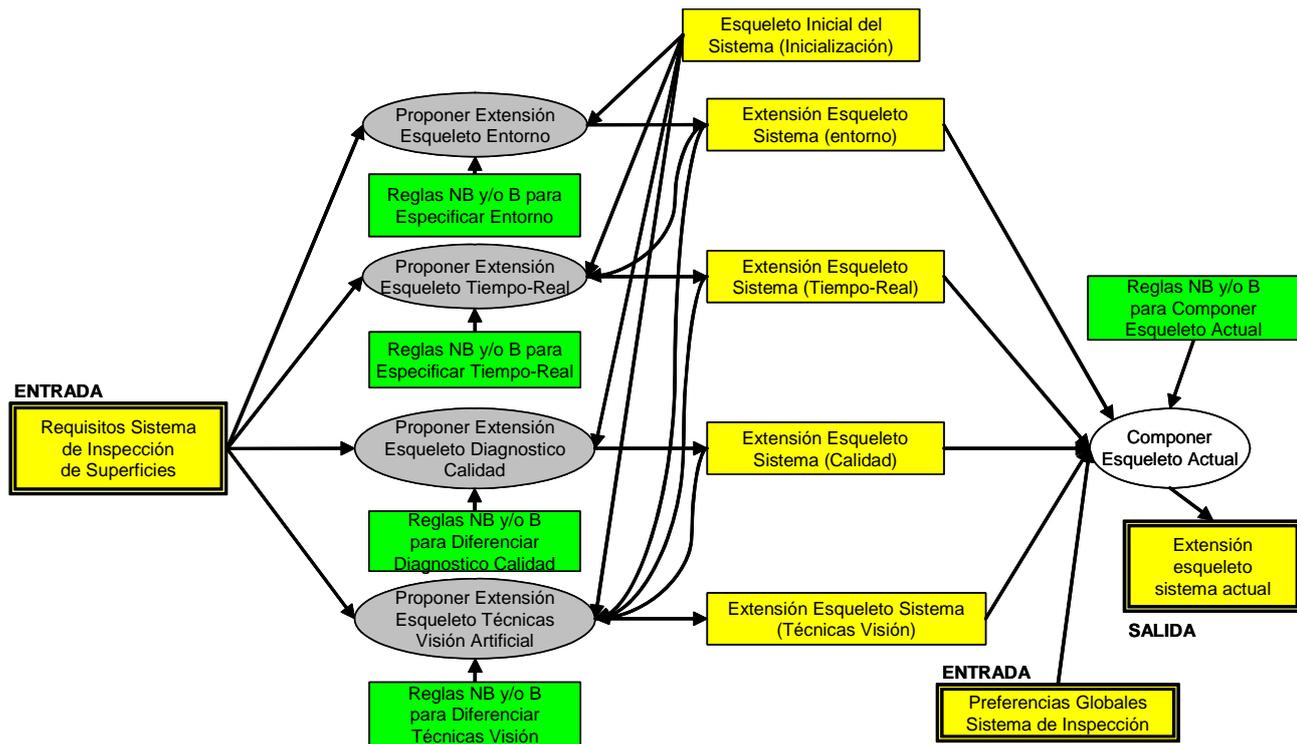


**Figura 5.6:** Descomposición jerárquica de la sub-tarea Proponer Sistema

El PSM utilizado para resolver esta sub-tarea de extensión del esqueleto inicial es *Descomponer-Configuración-En-Etapas* y permite diferenciar distintos tipos de conocimiento que influyen en la propuesta de extensión del esqueleto inicial del sistema de inspección. La figura 5.7 muestra el diagrama de subtareas e inferencias

del método.

El método tiene en cuenta los requisitos de entorno, tiempo-real, diagnóstico de calidad, técnicas de visión por computador y globales de la aplicación específica de inspección de superficies para configurar el sistema completo. La solución de la subtarea se obtiene en el rol dinámico «Extensión esqueleto sistema actual».



**Figura 5.7:** Diagrama de subtareas e inferencias del PSM Descomponer-Configuración-En-Partes para la subtarea Proponer Sistema

La estrategia para proponer la extensión del esqueleto-inicial del sistema de inspección de superficies sigue el siguiente procedimiento:

1. Las tres subtareas *Proponer-Extensión-Esqueleto-Entorno*, *Proponer-Extensión-Esqueleto-Tiempo-Real* y *Proponer-Extensión-Esqueleto-Diagnostico-Calidad*, proponen soluciones a las necesidades reflejadas en los “requisitos del sistema de inspección” de la aplicación de inspección de

una superficie relativas al entorno, tiempo-real y control de calidad. La salida de estas subtarear conectan con la subteara compleja *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*, que se describe a continuación.

2. La subteara compleja *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial* configura los componentes relativos a visión por computador, para inspección de superficies, usando las técnicas y métodos del dominio de inspección de superficies.
3. Finalmente, se compone el esqueleto actual ayudándose de los requisitos globales de la aplicación (por ejemplo, el requisito [Prioridad Extensión Configuración]={Entorno, Tiempo-real, Calidad}). De esta forma, se obtiene la configuración del sistema de inspección de superficies formada por un conjunto de componentes y sus respectivos parámetros. A continuación, el esqueleto actual o extensión del esqueleto inicial propuesto, pasa a la fase de revisión dentro de la teara principal de *Diseño-Configuración-de-Inspección-de-Superficies* antes de utilizarlo en la inspección de la línea de producción.

La extensión del esqueleto inicial se lleva a cabo, en cada subteapa (entorno, tiempo-real, diagnóstico de calidad, etc.), basándonos en:

1. Los requisitos de inspección de la superficie especializados en entorno, tiempo-real, diagnóstico de calidad, etc. que han sido seleccionados por el inspector de línea.
2. El conocimiento genérico del dominio de inspección de superficies relativo a entorno, tiempo-real, diagnóstico de calidad, etc.
3. El esqueleto inicial del sistema.

Así, por ejemplo, la subteara *Proponer-Extensión-Esqueleto-Entorno* propone los componentes de entorno para la extensión del esqueleto basándose en: los requisitos

---

Requisitos del sistema de inspección: <b>Requisitos de entorno</b>
--

---

Velocidad de línea de producción={0-10}m/seg Variable numérica => {baja, media, alta}Variable Abstracta B (Borrosa)
Distancia de seguridad SistemaÓptico-SuperficieAinspeccionar={0-1000}mm => {baja, media, alta}Variable Abstracta B
Orientación del Conjunto de Defectos={Longitudinal, Transversal, Diagonal, Indeterminado, Aleatorio}Variable Abstracta NB
Tipo de iluminación={Láser verde, Láser rojo, Luz blanca convencional, Fluorescente, Anillo leds}Variable Abstracta NB
Posición del Cjto. de Defectos={Fleje Inspector, Fleje Central, Fleje Motor}Variable Abstracta NB
Sistema físico de inspección={Basado en ilumi. láser coaxial, Basado en ilumi. láser exterior, Sistema convencional}Variable Abstracta NB

---

**Tabla 5.7:** Requisitos de entorno para la configuración del sistema de inspección de la superficie específica y sus valores posibles

especializados de entorno (tabla 5.7) que se encuentran en el rol dinámico «Requisitos Sistema de Inspección de Superficies», el conocimiento genérico de inspección de superficies relativo a entorno que se encuentra en el rol estático ‘Reglas NBy/oB para especificar entorno’ y el esqueleto inicial del sistema. Las tablas 5.8 y 5.9<sup>101112</sup> muestran un ejemplo de este tipo de conocimiento genérico de entorno del dominio de inspección de superficies utilizado en las inferencias de esta subtarea.

Las subtarear que amplían el esqueleto inicial del sistema siguen el orden siguiente: *Proponer-Extensión-Esqueleto-Entorno*, *Proponer-Extensión-Esqueleto-Tiempo-Real*, *Proponer-Extensión-Esqueleto-Diagnostico-Calidad* y *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*. Este orden (ver la estructura de control (apéndice D) para mayor detalle) permite:

---

<sup>10</sup>(Tabla 5.8) La resolución es en el sentido del tamaño del píxel en el plano objeto, es decir, en el material laminado. La “ResoluciónMínimaNecesaria” atendiendo al tamaño mínimo de los defectos superficiales determina qué longitud del plano objeto (plancha del material laminado) debe captar un píxel de la cámara

<sup>11</sup>(Tabla 5.8) número de filas y columnas

<sup>12</sup>(Tabla 5.8) ResoluciónSistemaÓptico es la separación angular más pequeña de dos puntos en el objeto inspeccionado que produce dos puntos distinguibles en la imagen

---

CONOCIMIENTO GENÉRICO UTILIZADO EN LAS INFERENCIAS DE LA SUBTAREA *Proponer-Extensión-Esqueleto-Entorno* (figura 5.7 y ver apéndice B)

---

ElementosRobotizadosDePosicionamiento={barridoPerpendiDirecciónAvance, movimientoVerticalEnfoque, zoomMotorizado, IrisMotorizado, Ninguno}

TipoCámara = {CámaraVideoColorDXC-950P\_3-CCD, CámaraVideoColorMitsubishiCCD-300E}

EnfoqueAutomático={RRNN, PropioCámara}

SistemaÓptico={PropioSistemaSIVAII, ÓpticaConvencional}

IntensidadLuminosa={baja, media, alta}

IluminaciónDifusa={verdadero, falso}

DireccionalidadDeLaLuz={verdadero, falso}

TiempoDeExposición={largo, medio, corto}

InterferenciaLuzAmbiente={Verdadero, Falso}

AperturaConjuntoLentes={Fija, Variable}

GananciaSensorCámara={Automático, Mínimo, Máximo}

PíxelesPorDefecto={4píxeles(2x2), 9píxeles(3x3), SelecciónManual}

CotaMínimaTamañoDefectos={17,2micras, 50micras, 100micras, 1mm}

DensidadPíxelesPorMilímetro(PPM)={233píxeles/mm, 40píxeles/mm, 20píxeles/mm}

ResoluciónEnPlanoObjeto(InversaDePPM)<sup>11</sup>={0.0086mm, 0.025mm, 0.050mm}

Difusor={verdadero, falso}

Encoder={verdadero, falso}

NaturalezaDeIluminación={pulsante, continua}

MecanismosDeSincronización={verdadero, falso}

ControlRemotoCámara={verdadero, falso}

ConfiguraciónParámetrosCámara={verdadero, falso}

ResoluciónDeImagen<sup>12</sup>={alta, media, baja}

ResoluciónNivelesDeGris={alta, media, baja}

ResoluciónSistemaÓptico<sup>13</sup>={alta, media, baja}

InterferenciaSpeckle={verdadero, falso}

Prefe.CosteComputacionalSistema={bajo, medio, alto}

Prefe.PosRelaCámara-SistemaDeIlumi={0grados, 45Grados, 90grados, SelecciónManual}

Prefe.PosiciónCámaraSistemaIlumi-PlanoDeInspección={ParteSuperior90grados, ParteInferior270grados, ambos}

Prefe.DistanceFocalLente={55mm, 160mm, SelecciónManual}

Prefe.DistanceAlPlanoObjetoDesdeLente={2f, SelecciónManual}

Prefe.DistanceAlPlanoImagenDesdeLente={2f, SelecciónManual}

Prefe.FactorMagnificaciónM={1, 0.4ParaPíxelEnPlanoImagen10micras, SelecciónManual}

Prefe.NúmeroF(F/#)={NúmeroF(F/#)5.5, NúmeroF(F/#)16, SelecciónManual}

---

**Tabla 5.8:** Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtaska *Proponer-Extensión-Esqueleto-Entorno* (figura 5.7)

---

CONOCIMIENTO GENÉRICO UTILIZADO EN LAS INFERENCIAS DE LA SUBTAREA *Proponer-Extensión-Esqueleto-Entorno* (continuación tabla 5.7)

---

Restri.AplicarFiltro={verdadero, falso}

Restri.SistemaFísicoDeInspección={ BasadoEnIlumiLáserCoaxial, BasadoEnIlumiLáserExterior, SistemaConvencional}

Restri.FalloDistanciaDeSeguridad={verdadero, falso}

Restri.CanalImagen={rojo, verde, azul}

Restri.TipoDeIluminación={LáserVerde, LáserRojo, LuzBlancaConvencional, Fluorescente, AnilloLeds}

Restri.PosRelaCámara-SistemaDeIlumi={0grados, 45Grados, 90grados, SelecciónManual}

Restri.TamañoDefectoMínimoDetectable={20micras, Entre0,05y0,1mm , MásDe0,1mm}

DefectosDetectablesAsimpleVistaEnImágenes={verdadero, falso}

ProfundidadDeCampoDOF={baja, media, alta}

RobustezSistemaFrenteAondulaciones={verdadero, falso}

ProbabilidadDetecciónDefecto={alta, media, baja}

ZoomRatio={bajo, medio, alto}

ConfiguraciónEntornoOptimo={OKConfiguración, FALLOConfiguración}

AcercarSistemaOpticoAlaSuperficieDeInspección={verdadero, falso}

FuenteDeLuz={Convencional, PulsanteDeAltaIntensidadLuminosa, IluminaciónLáser}

---

**Tabla 5.9:** Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea *Proponer-Extensión-Esqueleto-Entorno* (continuación tabla 5.7)

- Primero, extender el esqueleto en función del entorno y tiempo-real de la aplicación (es decir, de los requisitos relativos a los elementos físicos, al entorno industrial donde se instala el sistema, a las restricciones hardware de tiempo-real, etc.).
- Segundo, tener en cuenta las necesidades de control de calidad de la aplicación particular.
- Tercero, considerando las tres extensiones anteriores, se configuran los componentes de visión por computador.

Con esta estructura, las extensiones de entorno se contemplan en las subtareas de tiempo-real y técnicas de visión por computador y, por otro lado, también se tienen en cuenta las extensiones de tiempo-real y control de calidad en la subtarea de técnicas de visión por computador.

Finalmente, la inferencia *Componer-Esqueleto-Actual* compone todas las extensiones de esqueleto en el rol dinámico «Extensión esqueleto sistema actual» que contiene la configuración para resolver el problema de inspección de una superficie específica, previa a la revisión final como se ha comentado anteriormente.

Con este método, se contemplan las necesidades de entorno, tiempo-real, etc. de una aplicación de inspección de superficies (mediante los requisitos específicos) y se relacionan las extensiones de esqueleto para configurar el sistema de inspección de superficies. Así, por ejemplo, en el caso de extensión de tiempo-real (la tabla 5.10 muestra los requisitos de tiempo-real), el componente configurado {tiempo de exposición} (ayuda a medir el “tiempo-real de inspección”), juega un papel importante en el resto de extensiones. El tiempo de exposición para una aplicación de inspección de superficies depende de varios requisitos, como: el [tamaño del defecto a inspeccionar], la [velocidad de avance de la línea de producción], etc. Así pues, en función de los dos componentes de tiempo-real {tiempo de exposición} y {FotogramasPorSegundo} y el componente de entorno {TamañoBufferImagen} se calcula el

---

Requisitos del sistema de inspección: <b>Requisitos de tiempo-real</b>
Tipo de Ordenador={Convencional, Industrial, Portatil, Embebido}Variable Abstracta NB
Tipo Librerías Visión Artificial={Librerías Matlab, Librerías Mil, Librerías propias proyecto}Variable Abstracta NB
Velocidad de Procesado de Información Sistema={Alta sin visualización de defectos (solo estadísticas), Media con visualización de defectos (sin estadísticas), Baja con visualización de defectos y estadísticas}Variable Abstracta NB
Sensor fotoeléctrico={si, no}Variable Abstracta NB
Espectroscopia óptica={sí, no}Variable Abstracta NB
Enfoque auto cámara={si, no}Variable Abstracta NB
Enfoque auto RRNN={si, no}Variable Abstracta NB

---

**Tabla 5.10:** Requisitos de tiempo-real para la configuración del sistema de inspección de la superficie específica y sus valores posibles

componente {tiempo medio de inspección} para procesado de la imagen, que permite seleccionar mejor los componentes de visión por computador (más rápidos o precisos (más lentos)). Por lo tanto, en este ejemplo, la extensión de tiempo-real ayuda a seleccionar la técnica de segmentación o el mejor clasificador, entre otros, en la subtarea *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*. También, recordar que todas las extensiones que se realizan en esta etapa tienen como base el esqueleto inicial que se configuro en la subtarea inicial *Configurar-esqueleto-inicial*. La tabla 5.11 muestra un ejemplo de este tipo de conocimiento genérico de tiempo-real del dominio de inspección de superficies utilizado en las inferencias de esta subtarea de tiempo-real.

#### **5.5.4. Subtarea Proponer Extensión Esqueleto Técnicas Visión Artificial**

La inspección de superficies requiere una configuración detallada de las técnicas de visión por computador. Por tanto, la arquitectura ARDIS descompone en etapas la subtarea relativa a la configuración de las técnicas de visión por computador (segmentación, representación, descripción, detección, reconocimiento e interpretación).

---

CONOCIMIENTO GENÉRICO UTILIZADO EN LAS INFERENCIAS DE LA SUBTAREA *Proponer-Extensión-Esqueleto-Tiempo-Real* (figura 5.7 y ver apéndice B)

---

VariaciónTemporalCaracterísticasSuperficie={lenta, rápida}

EvitarActualizaciónUmbralEnCadaImagen={verdadero, falso}

AhorrarPorcentajeSignificativoDeCálculo={verdadero, falso}

GanarVelocidadDeInspección={verdadero, falso}

AumentarElÁreaInspeccionada={verdadero, falso}

AcelerarElCálculoDelMínimoDeLaImagen={verdadero, falso}

EstadísticamenteLosMínimosEstánAcotadosDentroDeCiertaIntervalo={verdadero, falso}

RecorrerLaImagenCompletaParaCalcularMínimoAbsoluto={verdadero, falso}

EmplearElPrimerMínimoEncontradoDentroDelIntervalo={verdadero, falso}

EfectosDeVariacionesLocalesDeIluminación={verdadero, falso}

AtenuandoConFragmentaciónEnSubimágenes={verdadero, falso}

EfectosDeVariacionesDeDistanciaEntreÓpticaYsuperficie={verdadero, falso}

EfectosDeVariacionesPorAberracionesÓpticas={verdadero, falso}

VariacionesLocalizadasEnLaPeriferiaDeLaImagen={verdadero, falso}

ProcesarSoloZonaCentral={selecciónManual, TantoPorCientoCentral, EliminarTantoPorCientoPeriferia}

ProcesadoGlobal={simple, complejo}

AcelerarElProcesoDeInspección={verdadero, falso}

AumentarProcesadoDeImágenesPorSegundo={verdadero, falso}

AumentarVelocidadDeTransferenciaDeImágenesDesdeCámaraSistemaAlmacenamiento = {verdadero, falso}

AumentarVelocidadDeTransferenciaDeImágenesDesdeCámaraSistemaProcesamiento = {verdadero, falso}

CuellosDeBotellaAdquisiciónDeImágenes={verdadero, falso}

CuellosDeBotellaProcesadoDeImágenes={verdadero, falso}

EnfoqueAutomático={RRNN, PropioCámara}

TiempoProcesamientoPorImagen={alto, medio, bajo}

CálculosAfectuarEnImagen={sencillos, intermedios, complejos}

PotenciaDelProcesador={alta, media, baja}

Prefe.TipoMemoriaIntermedia(Buffer)={HardwareDedicado, TarjetaDeAdquisición, Software}

Prefe.MemoriaIntermedia(Buffer)={alta, media, baja}

Prefe.CosteComputacionalDetecciónDefecto={alto, medio, bajo}

Restri.CapacidadDeProcesamientoImágenes={alta, media, baja}

Restri.ReducciónDeDatos={Imagen, SecuenciaDeImágenes}

Restri.FotogramasPorSegundo={alto, medio, bajo}

ReducirTiempoDeProcesamiento={verdadero, falso}

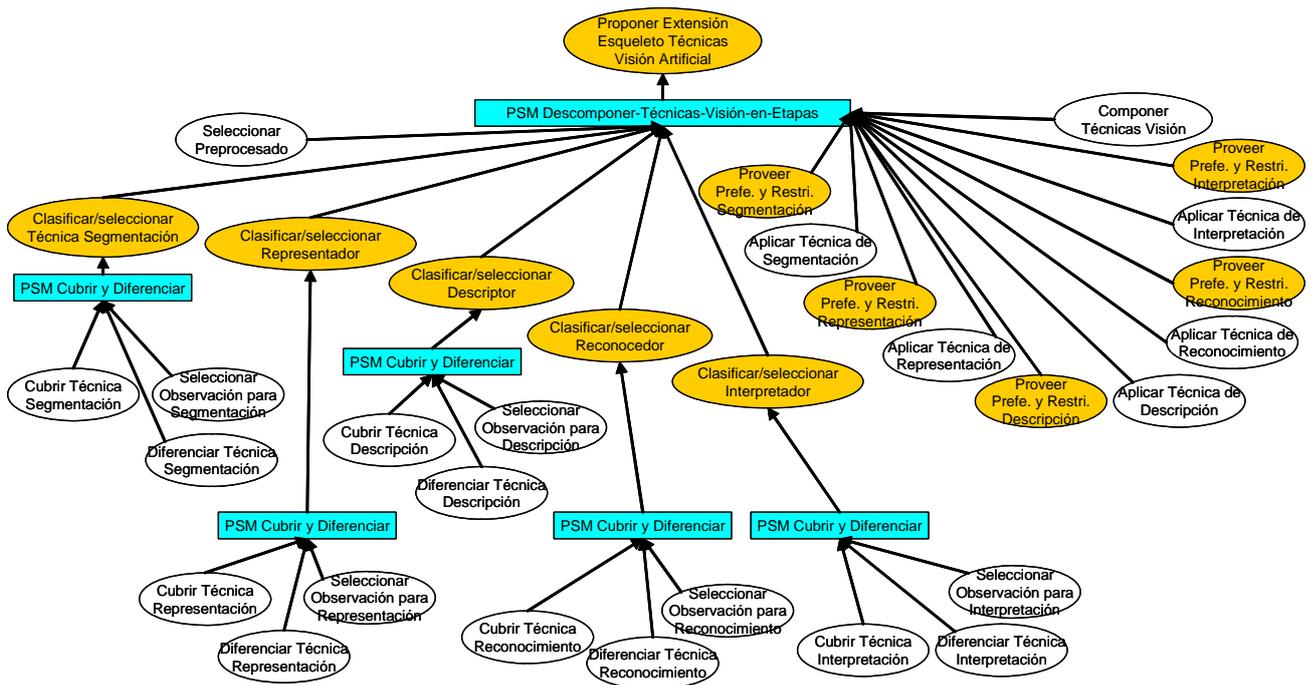
IncrementarNúmeroDeImágenesProcesadasPorSegundo={verdadero, falso}

---

**Tabla 5.11:** Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea *Proponer-Extensión-Esqueleto-Tiempo-Real* (figura 5.7)

La descomposición jerárquica de la subtarea compleja *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial* se muestra en la figura 5.8. La estructura de la solución de esta subtarea se fundamenta en las siguientes ideas:

- La solución de la subtarea compleja se lleva a cabo mediante el método *Descomponer-Técnicas-Visión-en-Etapas*, porque permite diferenciar las etapas de visión por computador (desde segmentación hasta interpretación).
- Las preferencias y restricciones específicas se proveen para cada subtarea de visión por computador: *Clasificar/seleccionar-Técnica-Segmentación*, *Clasificar/seleccionar-representador*, *Clasificar/seleccionar-Descriptor*, *Clasificar/seleccionar-Reconocedor* y *Clasificar/seleccionar-Interpretador*, con el objetivo de hacer más robusta la selección de cada técnica de visión por computador.
- Las subtarefas de visión por computador se resuelven mediante el PSM *Cubrir-y-Diferenciar*. Aquí se hace la conexión entre el alto y bajo nivel y se selecciona la técnica de visión por computador.
- La inferencia *Seleccionar-preprocesado* permite seleccionar los componentes de preprocesado, como por ejemplo, {canal de trabajo}, {tipo de filtro}, etc.
- La inferencia *Componer-Técnicas-Visión* reúne las técnicas de visión por computador seleccionadas y conforma el conjunto de componentes y sus parámetros de visión por computador apropiados para la inspección del defecto superficial.
- Las cinco inferencias para visualizar los resultados parciales de segmentación, representación, descripción, reconocimiento e interpretación, que muestran al inspector de línea el resultado de los componentes configurados sobre la imagen. Esto sólo sirve para seguir la evolución de la configuración de las técnicas de visión por computador.



**Figura 5.8:** Descomposición jerárquica de la subtarea Proponer Extensión Esqueleto Técnicas Visión Artificial

La figura 5.9 muestra el diagrama de subtarear e inferencias del método Descomponer-Técnicas-Visión-en-Etapas para la subtarea compleja *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*. El diagrama muestra la estrategia propuesta para resolver una de las subtarear más importantes de la tarea de *Diseño-Configuración de Inspección de Superficies*. Al igual que en las subtarear anteriores de la arquitectura ARDIS, la solución se basa en los requisitos proporcionados por el rol dinámico «Requisitos Sistema de Inspección de Superficies» (la tabla 5.12 muestra los requisitos de las técnicas de visión por computador) y en el conocimiento genérico del dominio de inspección de superficies.

Requisitos del sistema de inspección: **Requisitos de las técnicas de visión por computador**

Tipo de Defectos={ManchasSuperficiales, PequeñosDefectos, GrandesDefectos}

Forma de Defectos a Inspeccionar={Circular, Ovalado, Rectangular, Lineal, Cuadrado, Aleatorio, Amorfo}

Area Mínima del Defecto={0-100} mm<sup>2</sup>

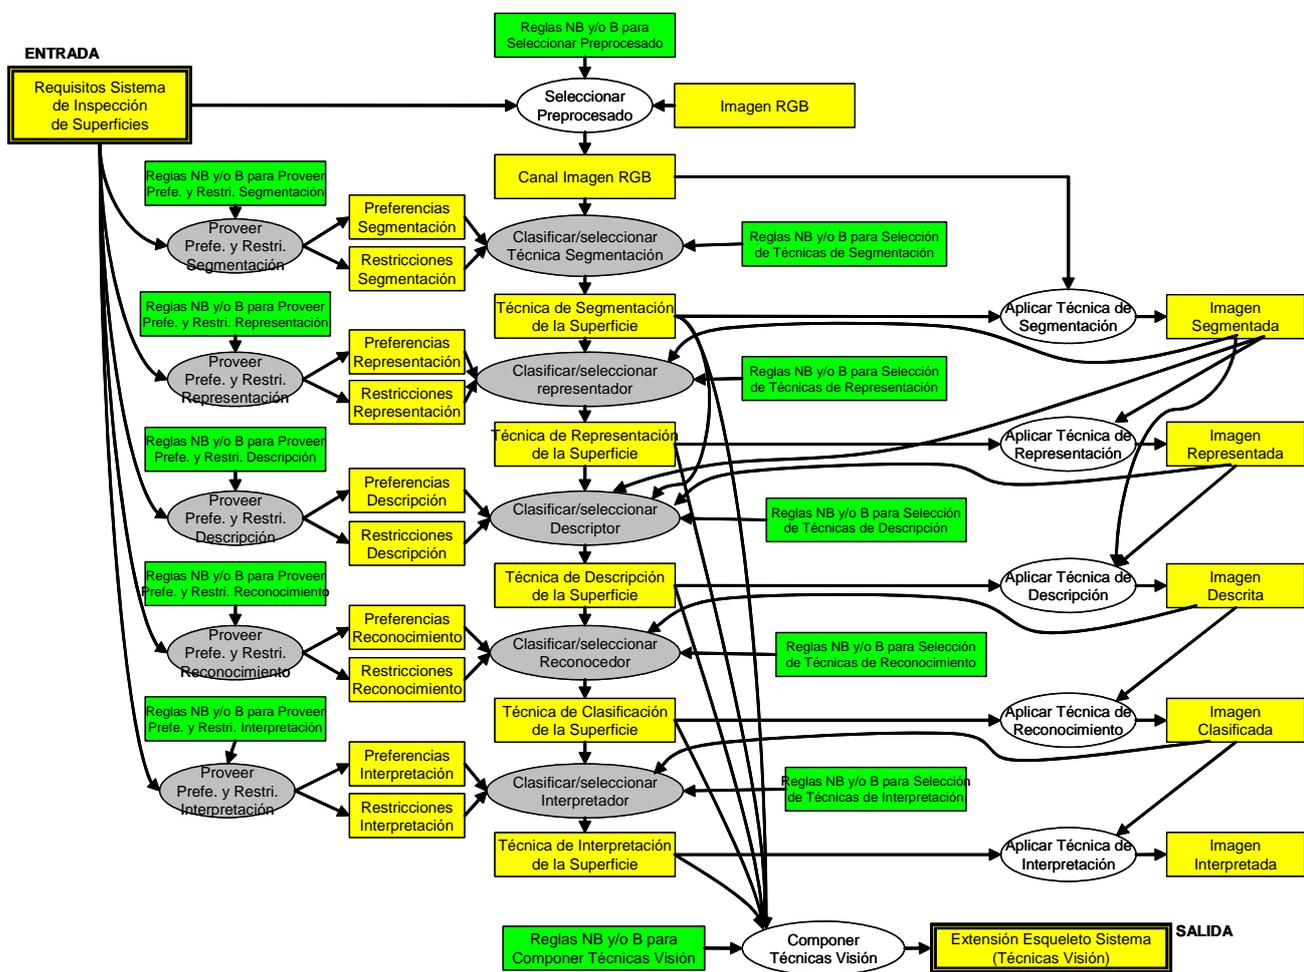
Área Máxima del Defecto={0-100} mm<sup>2</sup>

Numero de píxeles en la imagen que ocupa el defecto={0-100} píxeles

Compactabilidad del Defecto={si, no}

Aleatoriedad del Defecto={si, no}

**Tabla 5.12:** Requisitos de las técnicas de visión por computador para la configuración del sistema de inspección de la superficie específica y sus valores posibles



**Figura 5.9:** Diagrama de sub tareas e inferencias del PSM Descomponer-Técnicas-Visión-en-Partes para la sub tarea Proponer Extensión Esqueleto Técnicas Visión Artificial

La solución se obtiene en el rol dinámico «Extensión Esqueleto Sistema (Técnicas Visión)» y está compuesto por la secuencia de componentes de visión por computador (desde segmentación a interpretación) que permiten inspeccionar la superficie laminada concreta y satisfacer las necesidades del proceso de control de calidad en la línea de producción.

El método **Cubrir-y-Diferenciar**, resuelve las subtareas *Clasificar/seleccionar-Técnica-Segmentación*, *Clasificar/seleccionar-Representador*, *Clasificar/seleccionar-Descriptor*, *Clasificar/seleccionar-Reconocedor*, *Clasificar/seleccionar-Interpretador*, porque permite proponer varias hipótesis que pueden cubrir una restricción de la aplicación particular de inspección de superficies, relativa a segmentación, representación, etc.

La estructura de la solución propuesta se resume en el siguiente procedimiento:

1. Se proveen las preferencias y restricciones para cada subtarea de visión por computador.
2. A partir de una imagen capturada por el sistema de inspección, la inferencia *Seleccionar-Preprocesado* selecciona, con ayuda del rol estático 'Reglas NB y/o B para Seleccionar Preprocesado', el canal de trabajo apropiado, la composición de canales o el filtro apropiado.
3. A continuación, la subtarea *Clasificar/seleccionar-Técnica-Segmentación* configura la técnica de segmentación para el caso concreto en función de las preferencias y restricciones de segmentación, la propia imagen preprocesada, y la base de conocimiento para seleccionar las técnicas de segmentación. A continuación, la inferencia *Aplicar-Técnica-de-Segmentación* aplica la técnica de segmentación seleccionada a la imagen preprocesada. De esta forma, se muestra el resultado intermedio al inspector de línea o usuario experto para seguir la evolución de la configuración del sistema y también para poder utilizar la imagen segmentada en las siguientes dos subtareas de representación y des-

cripción (ver apéndice C).

4. El proceso anterior se repite para las subtareas *Clasificar/seleccionar-representador*, *Clasificar/seleccionar-Descriptor*, *Clasificar/seleccionar-Reconocedor* y *Clasificar/seleccionar-Interpretador*. El objetivo es configurar de forma secuencial los componentes relativos a las técnicas de visión, debido a que los resultados de una subtarea pueden influir en la siguiente.
5. El resultado final es la composición de todas las técnicas de visión por computador seleccionadas, para el caso concreto de inspección de superficies, mediante la inferencia *Componer-Técnicas-Visión*.

También es importante observar que las subtareas *Clasificar/seleccionar-representador* y *Clasificar/seleccionar-Descriptor*, y las inferencias *Aplicar-Técnica-de-Representación* y *Aplicar-Técnica-de-Descripción*, todas reciben la imagen segmentada. Esto se debe a la posibilidad de que el sistema de inspección de superficies no precise configurar las técnicas de representación y pase directamente de segmentar la imagen a describirla.

Este apartado pone especial atención en el tipo de conocimiento utilizado en la solución de la subtarea compleja *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*. Así, la tabla 5.13 muestra un ejemplo del tipo de conocimiento del dominio de inspección de superficies relativo a las técnicas de visión por computador y la tabla 5.14<sup>13</sup>, otro ejemplo, también del tipo de conocimiento genérico de técnicas de visión por computador del dominio de inspección de superficies utilizado en las inferencias de esta subtarea.

---

<sup>13</sup>(Tabla 5.14) Estas variaciones aparecen debido a ondulaciones en el material laminado o a la curvatura de los rodillos

---

TIPO DE CONOCIMIENTO DEL DOMINIO DE INSPECCIÓN DE SUPERFICIES:  
TÉCNICAS DE VISIÓN POR COMPUTADOR

---

**Segmentación**

Detección de discontinuidades, Umbralización, Crecimiento de regiones, División y fusión de regiones, Movimiento, Línea divisoria de aguas

---

**Morfología Matemática**

Extracción de contornos, Relleno de regiones, Componentes conexas, Engrosamiento, Esqueletos, Gradiente morfológico

---

**Representación**

Códigos de cadena, Aproximaciones poligonales, Firmas, Lados del contorno, Esqueleto de una región

---

**Descripción mediante contorno**

Longitud, Diámetro, Curvatura, Descriptores de Fourier, Momentos

---

**Descripción mediante región**

Área, Perímetro / Densidad, Ejes principales, Número de Euler, Textura / Métodos estadísticos, Textura / Métodos espectrales

---

**Reconocimiento**

Clasificador de mínima distancia, Correspondencia por correlación (FFT), Redes neuronales, Correspondencia de cadenas, Patrón de Rugosidad/ "Speckle"

---

**Interpretación**

Genéticos, Redes neuronales, Borrosos, Estadísticos

---

**Tabla 5.13:** Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): técnicas de visión por computador

---

**CONOCIMIENTO GENÉRICO UTILIZADO EN LAS INFERENCIAS DE LA SUBTAREA *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*** (figura 5.9)

---

ImágenesEnColor={verdadero, falso}
ObtenciónDelMínimoDeLaImagen={verdadero, falso}
ReescaladoDeLaImagen={verdadero, falso}
FragmentaciónEnSubimágenes={verdadero, falso}
LocalizaciónDelMínimoDeLaSubimagen={verdadero, falso}
ObtenciónDeRegión50x50AlrededorDelMínimo={verdadero, falso}
FiltradoDelUmbral={verdadero, falso}
Umbralización={verdadero, falso}
ProcesamientoEstadístico={verdadero, falso}
EliminarVariacionesIluminación <sup>14</sup> ={verdadero, falso}
AplicarFiltro={FiltrarPasoAlta, FiltrarPasoBaja, FiltradoDeMediana}
NivelesDeGrisDefectoUniformes={verdadero, falso}
TipoDeVecindad={Vecindad4, vecindad8}
UtilizarRegiónDeInterés(ROI)={verdadero, falso}
Centroide={verdadero, falso}
CódigoDeCadena={verdadero, falso}
AumentarContraste={verdadero, falso}
Erosión={verdadero, falso}
Dilatación={verdadero, falso}
NúmeroDeEuler={verdadero, falso}
TransformadaRápidaDeFourier={verdadero, falso}
TransformaciónGeométrica={rotación, translación, deformación}
LookUpTable(LUT)={verdadero, falso}
TipoLookUpTable(LUT)={FFT, MapeadoIntensidadLog, MapeadoIntensidadExp, MapeadoIntensidadCuadrado, MapeadoIntensidadRaiz, CorrecciónGamma, EcuaciónHistograma}
TipoMedidaTamañoDefecto={Área, DimensiónMínimoRectánguloEncerrado, DiámetroCircunferenciaEncerrada, ÁreaConvexHull}
ContrasteEspacial={DiferenciaBrillo, DiferenciaColor, DiferenciaTextura}
FrecuenciaEspacial={VelocidadCambioEnEspacioBrillo, VelocidadCambioEnEspacioColor, VelocidadCambioEnEspacioTextura}
CalculoValorMedioIntensidadImagen={verdadero, falso}
AñadirConstanteIntensidadImagen={verdadero, falso}
ÁreaDefectoEnImagenBinaria={verdadero, falso}
ReescalaDeIntensidad={verdadero, falso}
MínimoRectánguloQueContieneAlDefecto={verdadero, falso}
DetecciónDeBorde={verdadero, falso}
RellenarAgujerosEnImagenBinaria={verdadero, falso}
FiltroMorfológicoBottonHat={verdadero, falso}
CentroidesDeDefectosEnImagenBinaria={verdadero, falso}
EliminarPíxelesBlancosAislados={verdadero, falso}

---

**Tabla 5.14:** Tipo de conocimiento genérico del dominio de inspección de superficies utilizado en las inferencias de la subtarea *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial* (figura 5.9)

#### 5.5.4.1. Subtarea Clasificar/seleccionar Técnica Segmentación

La subtarea *Clasificar/seleccionar Técnica Segmentación* es una de las cinco sub-tareas de la subtarea *Proponer-Extensión-Esqueleto-Técnicas-Visión-Artificial*, donde se realiza la conexión entre el alto nivel y el bajo nivel para clasificar/seleccionar la técnica apropiada de segmentación del caso concreto de inspección de una superficie.

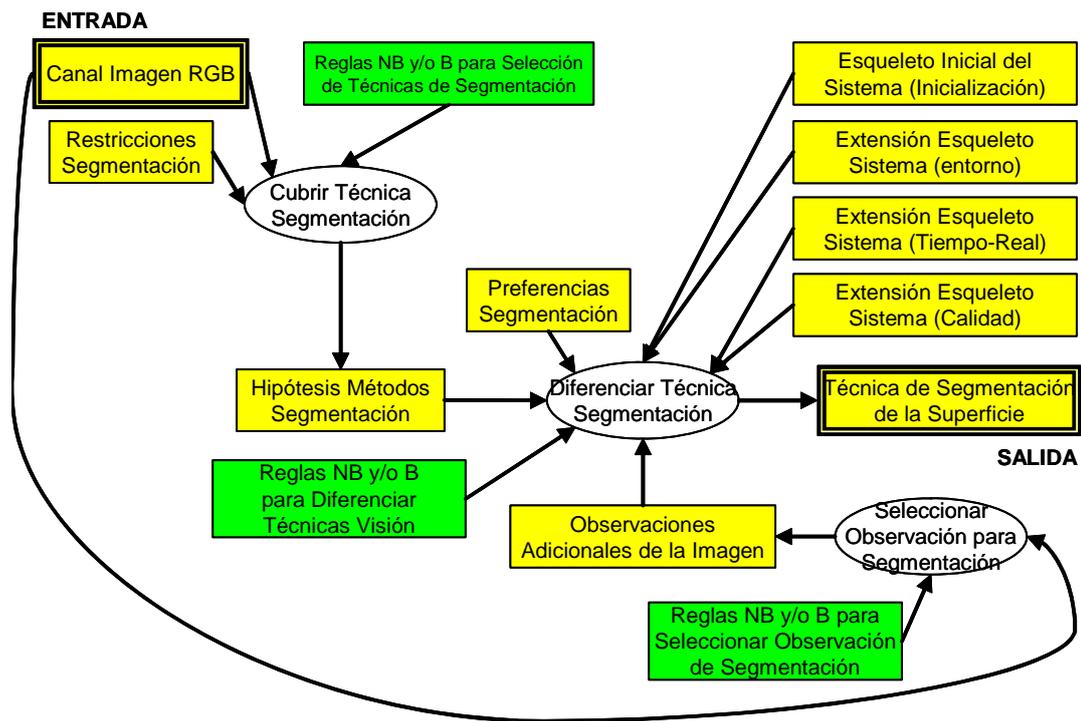
Así pues, del alto nivel llegan los requisitos de inspección, el esqueleto inicial, las extensiones de esqueleto de otras sub-tareas, etc., y por el bajo nivel, nos encontramos con la propia imagen capturada, es decir, con las observaciones que se pueden extraer directamente de ella. Un ejemplo de observación es el “menor nivel de gris de la imagen capturada” que ayuda a seleccionar el umbral apropiado para segmentar la imagen, en el caso que los defectos sean oscuros. A continuación se muestra un pequeño ejemplo de la base de conocimiento que utiliza el rol estático ‘Reglas NB y/o B para Diferenciar Técnicas Visión’:

SI NB\_Forma es Circular Y B\_NivelDeGrisImagenMinimoMedio es Oscuro ENTONCES DefectoSuperficial es Verdadero

SI NB\_PreferenciaDefecto es ReflectanciaDelDefecto Y NB\_DefectoSuperficial es Verdadero ENTONCES TécnicaSegmentación es Umbralización

SI NB\_PreferenciaDefecto es FormaDelDefecto Y NB\_DefectoSuperficial es Verdadero ENTONCES TécnicaSegmentación es DetecciónDeDiscontinuidades

La figura 5.10 presenta el diagrama de sub-tareas e inferencias del método *Cubrir-y-Diferenciar* para la subtarea *Clasificar/seleccionar-Técnica-Segmentación*. Las otras sub-tareas de visión por computador (representación, descripción, reconocimiento e interpretación), también utilizan la misma estructura.



**Figura 5.10:** Diagrama de subtareas e inferencias del PSM Cubrir-y-Diferenciar para la subtarea Clasificar/seleccionar Técnica Segmentación

En esta etapa de la arquitectura ARDIS, la secuencia de control es la siguiente (ver apéndice D):

1. La imagen capturada y las restricciones de segmentación son los roles dinámicos de entrada a la inferencia *Cubrir-Técnica-Segmentación*, que con ayuda del conocimiento genérico del dominio de inspección de superficies para la inferencia de segmentación, se proponen varias hipótesis (técnicas de segmentación) que pueden cumplir (cubrir) una restricción de segmentación para la aplicación particular de inspección de superficies.
2. Las observaciones de la imagen se seleccionan a través de la inferencia *Seleccionar-Observación-para-Segmentación*.
3. La lista de técnicas o métodos de segmentación, junto con las preferencias

---

 TIPO DE CONOCIMIENTO DEL DOMINIO DE INSPECCIÓN DE SUPERFICIES:  
 TÉCNICAS PARA SEGMENTAR DEFECTOS SUPERFICIALES
 

---

**Discontinuidad en los niveles de gris**

Bordes, líneas, puntos o contornos {Rapidez, Robustez, Eficiencia, Postprocesado, Reusabilidad}

---

**Similitud en los niveles de gris**

Umbralización {Rapidez, Robustez, Eficiencia, Postprocesado, Reusabilidad}

Regiones {Rapidez, Robustez, Eficiencia, Postprocesado, Reusabilidad}

Movimiento {Rapidez, Robustez, Eficiencia, Postprocesado, Reusabilidad}

---

**Mixto**

Línea divisoria de aguas (transformada “Watershed”) {Rapidez, Robustez, Eficiencia, Postprocesado, Reusabilidad}

---

**Tabla 5.15:** Tipo de conocimiento del dominio de inspección de superficies (independiente de la aplicación): propiedades de las técnicas para segmentar defectos superficiales; y sus valores posibles

de segmentación, son dos de los roles dinámicos de entrada a la inferencia *Diferenciar-Técnica-Segmentación*. Los otros roles dinámicos de entrada se pueden dividir en dos grupos, por un lado, llegan las posibles técnicas que se hayan seleccionado en otras inferencias o subtareas debido a las características de entorno, tiempo-real, etc. de la aplicación específica; y por otro lado, tenemos el esqueleto inicial del sistema, que posee una técnica de segmentación ya seleccionada. Todo este conocimiento dinámico, junto con el conocimiento estático del dominio de inspección de superficies ‘Reglas NBy/oB para diferenciar técnicas visión’, permite diferenciar una técnica de segmentación de las propuestas en el rol dinámico «Hipótesis Métodos Segmentación» para la aplicación específica de inspección de una superficie.

A continuación, se muestra el tipo de conocimiento utilizado en la solución de la subtaska *Clasificar/seleccionar Técnica Segmentación* (tabla 5.15). Por tanto, se formaliza el conocimiento genérico que posteriormente se usará en las reglas clásicas y borrosas de la base de conocimiento de inspección de superficies.

La primera técnica de segmentación mostrada en la tabla 5.15 obtiene el contorno de las regiones y consiste en dividir una imagen basándose en los cambios/discontinuidades bruscos/as de los niveles de gris (el resultado es un conjunto de píxeles que forman el borde del objeto). La segunda segmenta el área de las regiones mediante el histograma de la imagen y la tercera, también obtiene el área pero a partir de la técnica de crecimiento de regiones. Estas dos últimas se fundamentan en la similitud de los niveles de gris. La cuarta segmenta la imagen basándose en el movimiento y finalmente, la quinta corta la imagen en sus objetos básicos utilizando la transformada de “Watersheds”.

La segmentación de la imagen mediante técnicas de contorno se utiliza si el interés radica en las características de la forma exterior del defecto (con bordes bien definidos). Pero, en el caso de detección de defectos amorfos es recomendable localizar la región del defecto (segmentar el área del defecto), en vez del contorno. Además, en este caso, localizar el contorno de un defecto amorfo no interesa, porque supone un coste computacional elevado para inspección en una línea de producción.

Otros atributos del contorno del defecto superficial, además del carácter amorfo, son las esquinas, las inflexiones, etc.

### **5.5.5. Mecanismo de razonamiento**

El conjunto de reglas clásicas y borrosas — que conforman el conocimiento estático de cada inferencia — componen el mecanismo de razonamiento en la arquitectura ARDIS. El mecanismo de razonamiento en la arquitectura ARDIS se basa en las cuatro ideas siguientes:

1. La arquitectura ARDIS razona con encadenamiento hacia adelante, usando hechos (requisitos, preferencias, restricciones, etc.) y reglas para derivar nuevos hechos (por ejemplo, configuración de componentes del sistema de inspección). Es decir, en cada inferencia, a partir de un conjunto de datos del rol dinámico

de entrada se utilizan las reglas apropiadas para derivar los nuevos datos de configuración en el rol dinámico de salida. Las reglas se activan o disparan cuando sus antecedentes son ciertos.

2. Las reglas de producción especializadas de cada inferencia están compuestas por antecedentes clásicos y/o borrosos. Los antecedentes clásicos constan de variables lingüísticas. En el caso de un antecedente formado por una variable numérica, ésta se asocia a un conjunto borroso previamente definido. En ambos casos, el consecuente es lingüístico. En el caso clásico, el consecuente lingüístico es directo, y en el caso numérico se obtiene un consecuente lingüístico mediante el procedimiento que se explica en el siguiente apartado. Por tanto, internamente, siempre nos vamos a encontrar con consecuentes lingüísticos en la arquitectura ARDIS. Esta estrategia facilita y agiliza la solución de la tarea de *Diseño-Configuración de Inspección de Superficies* debido a que toda la información fluye de forma lingüística dentro de la arquitectura. El conocimiento así representado resulta muy cercano al operador humano y se puede entender fácilmente.
3. Una estrategia de control sencilla y rápida. Las reglas se crean lo más genéricas posible para cada inferencia. El diseñador o usuario experto introduce conocimiento genérico, de forma que se puede reutilizar para cada caso concreto de inspección de superficie. Por otro lado, en el caso de que se disparen dos o más reglas a la vez, se eligen de forma sucesiva comenzando por la primera.
4. El mecanismo de inferencia utiliza una estrategia de encadenamiento hacia adelante y una regla disparada no se puede volver a disparar (esto restringe el número de encadenamientos para agilizar el proceso de razonamiento (tiempo-real de la aplicación)).

#### 5.5.5.1. Método de razonamiento borroso

El método borroso utilizado en la arquitectura ARDIS se basa en el método de Mamdani [Mamdani & Assilian, 1975], [Mamdani, 1976], [Mamdani, 1977], donde se razona a partir de entradas numéricas y se obtiene una salida numérica y lingüística (según el caso se puede utilizar una u otra). El resultado numérico sigue el método de Mamdani y se utiliza para configurar, por ejemplo, un parámetro numérico del sistema de inspección. El resultado lingüístico se basa también en el método de Mamdani, pero la salida se calcula mediante el máximo de cada función de pertenencia en el centro de masas global. Así, la función de pertenencia cuyo máximo sea el mayor en el centro de masas global obtiene el resultado lingüístico de salida.

Este método permite razonar con información numérica aportada por el inspector de línea en los requisitos del sistema de inspección. Por ejemplo, en la configuración de un sistema de inspección de superficies nos encontramos con requisitos decisivos de carácter numérico como [Velocidad\_de\_línea\_de\_producción], [Área\_Mínima\_del\_Defecto], [Área\_Máxima\_del\_Defecto], [Número\_de\_píxeles\_en\_la\_imagen\_que\_ocupa\_el\_defecto], etc. Los requisitos numéricos se interpretan mediante conjuntos borrosos, como {baja, media, alta} o {grande, normal, pequeña} y están basados en distintas funciones de pertenencia (triangular, trapezoidal, gaussiana, etc.).

Las variables numéricas se usan de tres formas en la arquitectura ARDIS, la primera está basada en métodos clásicos de cálculo y la segunda y tercera son relativas al razonamiento borroso:

1. La primera utiliza requisitos numéricos seleccionables por el inspector de línea, y por métodos clásicos de cálculo se obtiene una solución numérica. Un ejemplo es el cálculo del tiempo de exposición a partir de las ecuaciones vistas en el capítulo 3. En este caso, no es necesario razonamiento borroso debido a que el origen de las variables es numérico y el resultado también es

numérico. Como se vio anteriormente, capítulo 3, el tiempo de exposición se calcula a partir de los siguientes tres requisitos del sistema de inspección: [Velocidad\_de\_línea\_de\_producción], [Área\_Mínima\_del\_Defecto] y [Número\_de\_píxeles\_en\_la\_imagen\_que\_ocupa\_el\_defecto].

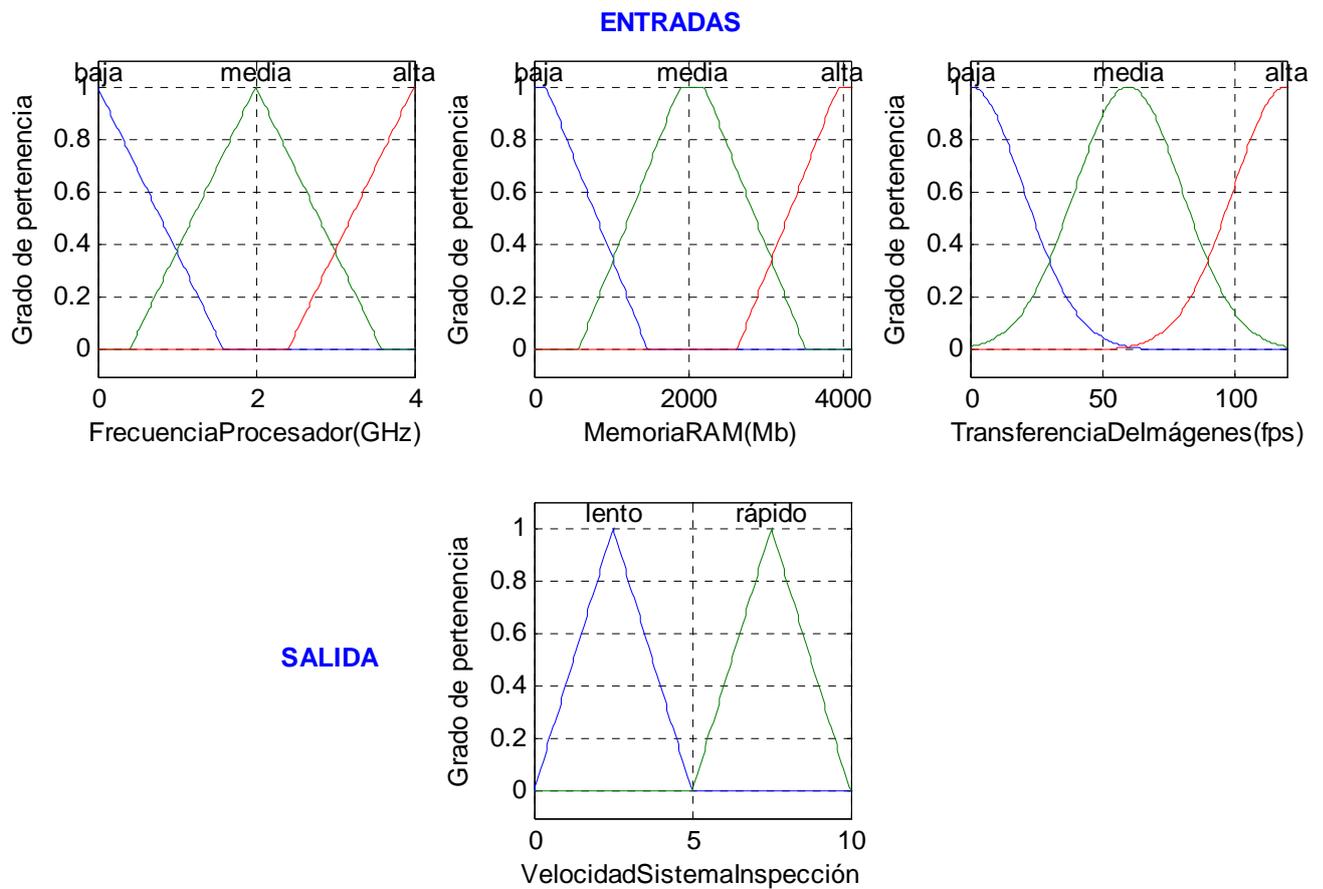
2. La segunda forma utiliza los requisitos del sistema de inspección y el método de Mamdani para obtener un resultado numérico. Las variables numéricas se interpretan mediante varios conjuntos borrosos y, a partir de un grupo de reglas relativas a los conjuntos borrosos (entradas y salida), se asignan varios valores numéricos asociados al conjunto borroso de salida. Finalmente, utilizando el método de agrupación y el centro de masas global se obtiene el valor numérico de la variable de salida.
3. La tercera forma es igual que la anterior, pero al final se obtiene un resultado lingüístico. El resultado numérico se obtiene igual que en el caso anterior, mediante el cálculo del centro de masas global. Pero, en este caso, se calcula el máximo en el punto del centro de masas global de cada elemento del conjunto borroso de salida. De esta forma, se puede calcular el mayor máximo en el punto del centro de masas global. Así pues, el elemento lingüístico del conjunto borroso de salida, correspondiente al mayor máximo, es el valor lingüístico de la variable de salida.

A continuación se muestra un ejemplo del caso 2 y 3 (un ejemplo del caso 1, se puede consultar en el capítulo 3, donde se calcula el tiempo de exposición para inspección de defectos de cascarilla residual en planchas de acero inoxidable). En este ejemplo, del caso 2 y 3, además se utiliza este tiempo de exposición calculado, como variable de entrada numérica en un proceso de razonamiento borroso.

Primero se utiliza un razonamiento borroso para obtener la velocidad de respuesta del sistema de inspección (sistema rápido o lento (salida lingüística) o un valor entre 0 y 10 (salida numérica)) a partir de tres entradas numéricas.

Segundo, mediante otro procedimiento borroso se obtiene el tiempo de procesado por imagen (tiempo bajo o normal o alto (salida lingüística) o un valor entre 0 y 1 seg (salida numérica)), que dispone el sistema de inspección para llevar a cabo las técnicas de visión por computador, seleccionadas para el caso concreto de inspección de superficies. En este caso concreto, el segundo razonamiento puede encadenar la solución del primer razonamiento, porque ambos poseen el mismo rango [0 – 10] numérico. Entonces, hay que observar que en el segundo razonamiento sólo se utiliza el resultado numérico y no el lingüístico del primer razonamiento. El resultado lingüístico no se puede utilizar porque el conjunto borroso de salida en el primer razonamiento es distinto al conjunto borroso de entrada en el segundo razonamiento. Así pues, lento y rápido en la salida del primer razonamiento no es lo mismo que lento y rápido en el segundo razonamiento, pero la variable numérica sin embargo es la misma.

Las entradas y la salida en el primer razonamiento borroso se muestran en la figura 5.11. Las variables numéricas de entrada se interpretan mediante el conjunto borroso {baja, media, alta} y la salida con el conjunto borroso {lento, rápido}. Las funciones de pertenencia se han seleccionado de forma empírica, para la primera variable de entrada se seleccionan funciones de pertenencia triangulares, para la segunda trapezoidales y gaussianas para la tercera. La salida está formada por dos funciones de pertenencia triangulares.

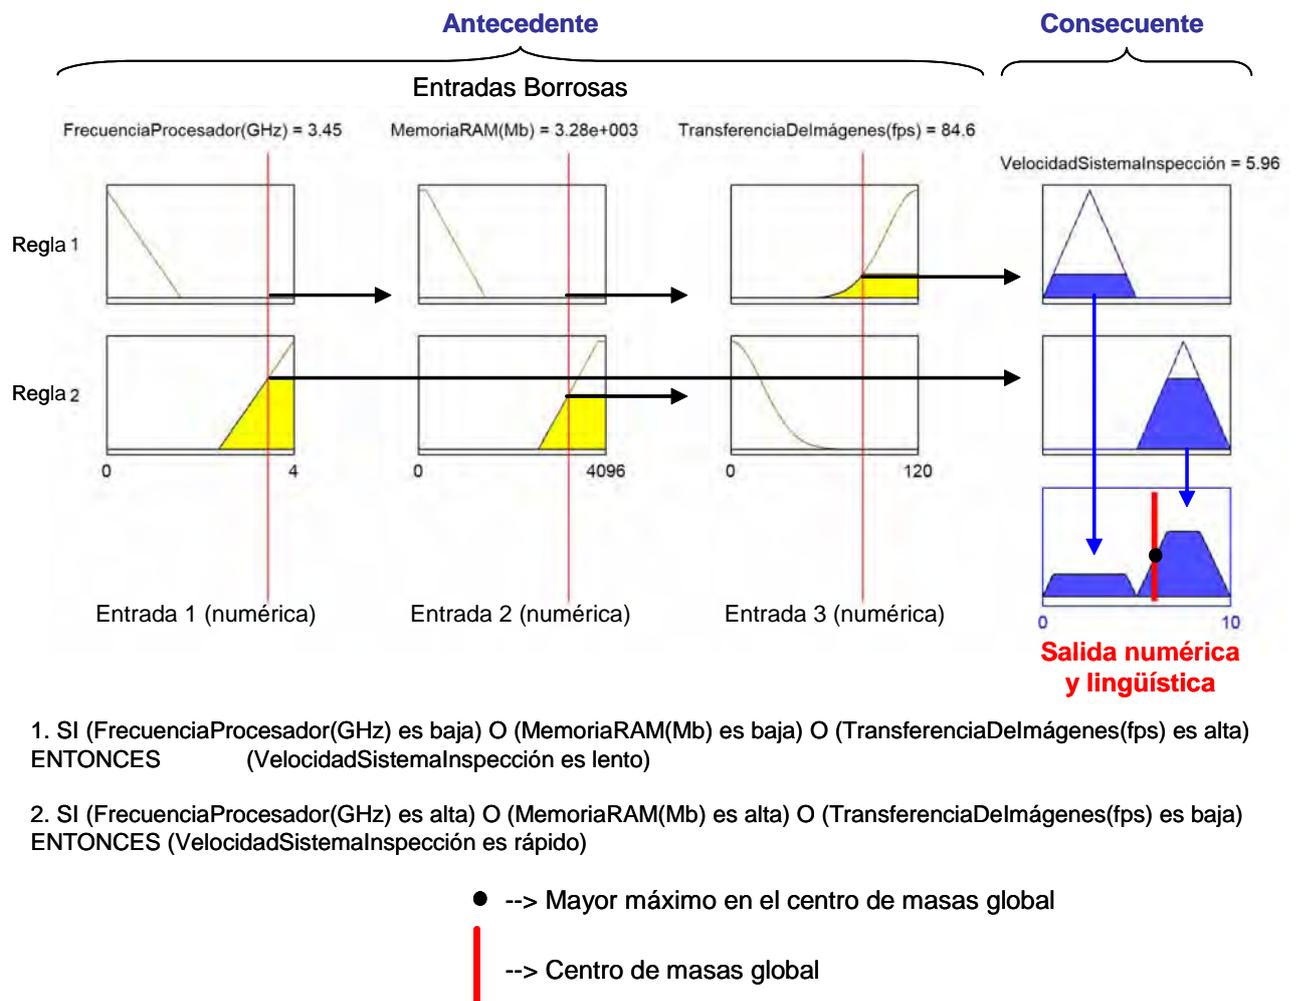


**Figura 5.11:** Entradas [Frecuencia Procesador (GHz)], [Memoria RAM (Mb)] y [Transferencia de Imágenes (fps)] en el razonamiento borroso para obtener la salida [Velocidad Sistema Inspección] (numérica y lingüística)

La figura 5.12 muestra el primer proceso de razonamiento borroso (entradas, conjuntos borrosos, reglas, salida, etc.). El primer paso, son las tres entradas numéricas, que pueden ser requisitos del sistema de inspección seleccionados por el inspector de línea o alguna variable numérica configurada en otro proceso de razonamiento. El segundo paso son los conjuntos borrosos definidos para cada variable numérica (entrada y salida) (figura 5.11). El tercero, son las reglas de la base de conocimiento que están basadas en elementos lingüísticos de los conjuntos borrosos de las variables (entrada y salida). El siguiente paso utiliza la operación O ( $O = \text{máximo}$ ) en

el antecedente de cada regla (color amarillo en la figura 5.12). A continuación se utiliza el método de implicación en cada regla (mínimo en la función de pertenencia de salida; color azul en la figura 5.12). Seguidamente, el método de agrupación (máximo) combina los conjuntos borrosos que representan la salida de cada regla en un único conjunto borroso. Finalmente, se calcula el centro de masas global para la salida numérica y los máximos en el punto del centro de masas global para la salida lingüística.

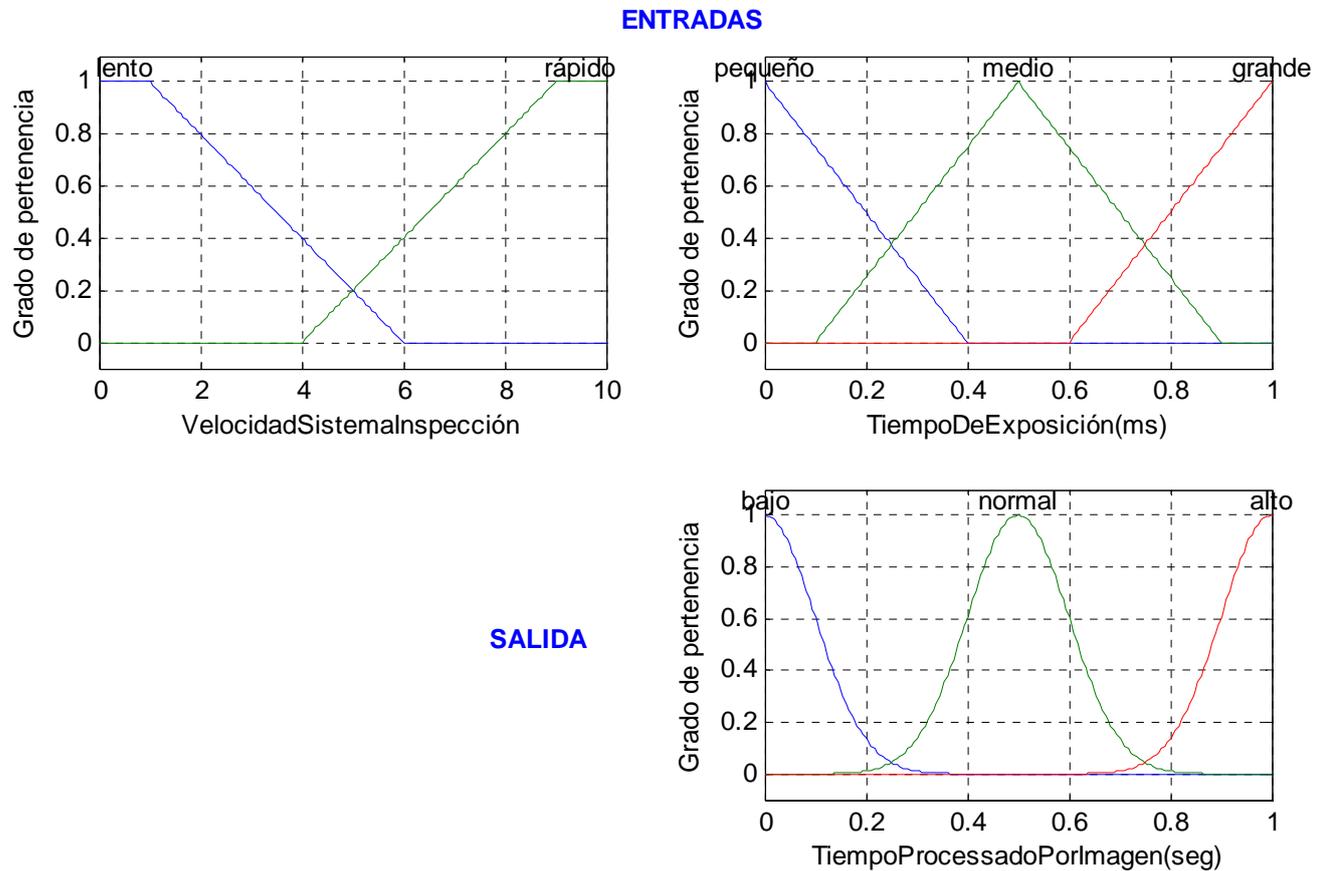
En concreto en el ejemplo (figura 5.12), se observan tres entradas numéricas [Frecuencia Procesador (GHz)] = 3,45 GHz, [Memoria RAM (Mb)] = 3280 Mb y [Transferencia de Imágenes (fps)] = 85 fps, y dos reglas con antecedentes (variables de entrada) y consecuentes (variables de salida) que utilizan elementos lingüísticos de los conjuntos borrosos de entrada y salida (figura 5.11). Finalmente, la salida numérica es [Velocidad Sistema Inspección] = 5,96 (para el rango 0-10, donde cero es muy lento y 10 muy rápido) y la salida lingüística es “rápido” debido a que el mayor máximo en el punto del centro de masas global pertenece al elemento lingüístico rápido del conjunto borroso de salida. El máximo perteneciente al elemento “rápido” del conjunto borroso de salida {lento, rápido} es distinto de cero, mientras que el máximo perteneciente al elemento “lento” del conjunto borroso de salida {lento, rápido} es cero.



**Figura 5.12:** Proceso de razonamiento borroso en la arquitectura ARDIS para obtener la salida [Velocidad Sistema Inspección] (numérica y lingüística)

Las entradas y salida del segundo razonamiento borroso se muestran en la figura 5.13. En este caso, se encadena la salida numérica del razonamiento anterior y se utiliza la variable numérica calculada mediante las ecuaciones del capítulo 3. Así, tenemos las siguientes dos entradas numéricas: [Velocidad Sistema Inspección] y [Tiempo de Exposición (ms)]. La primera se interpreta mediante un conjunto borroso {lento, rápido} con funciones de pertenencia trapezoidales. La segunda entrada utiliza un conjunto borroso {pequeño, medio, grande} con funciones de pertenencia

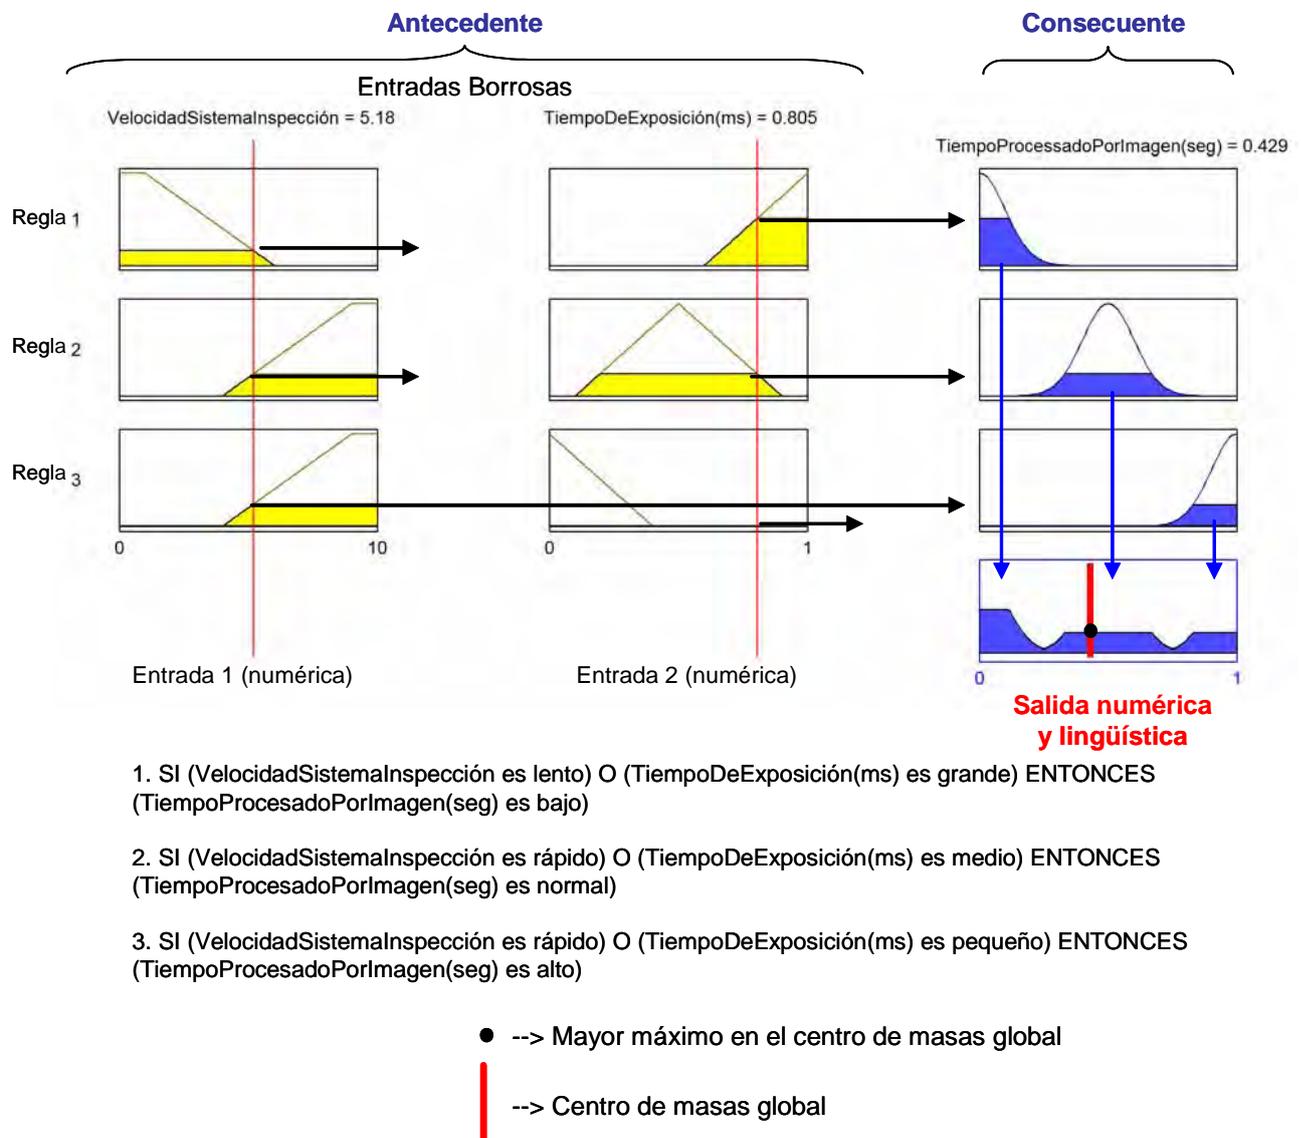
triangulares. Finalmente, la salida [Tiempo Procesado por Imagen (seg)] se basa en el conjunto borroso {bajo, normal, alto} y las funciones de pertenencia son gaussianas.



**Figura 5.13:** Entradas [Velocidad Sistema Inspección] y [Tiempo de Exposición (ms)] en el razonamiento borroso para obtener la salida [Tiempo Procesado por Imagen (seg)] (numérica y lingüística)

El proceso de razonamiento borroso para la variable de salida [Tiempo Procesado por Imagen (seg)] se muestra en la figura 5.14. Al igual que antes, el proceso de inferencia borrosa se compone de varias partes: primero las variables numéricas se interpretan mediante los conjuntos borrosos de entrada; segundo, se aplica el operador borroso O en el antecedente de cada regla; tercero, se utiliza el método de

implicación desde el antecedente al consecuente de cada regla; cuarto, se utiliza el método de agrupación (máximo) con los consecuentes de las reglas; Finalmente, se calcula el centro de masas global y los máximos.



**Figura 5.14:** Proceso de razonamiento borroso en la arquitectura ARDIS para obtener la salida [Tiempo Procesado por Imagen (seg)] (numérica y lingüística)

En concreto esta segunda parte del ejemplo (figura 5.14), utiliza dos entradas numéricas [Velocidad Sistema Inspección] = 5,18 y [Tiempo de Exposición (ms)]

= 0,805 mseg, y dos reglas con antecedentes (variables de entrada) y consecuentes (variables de salida) que utilizan elementos lingüísticos de los conjuntos borrosos de entrada y salida (figura 5.13). Finalmente, la salida numérica es [Tiempo Procesado por Imagen (seg)] = 0,429 seg (para el rango 0-1 seg, donde un valor cercano a cero es muy poco y 1 seg demasiado tiempo) y la salida lingüística es “normal” debido a que el máximo en el punto del centro de masas global perteneciente al elemento “normal” del conjunto borroso de salida {bajo, normal, alto} es el mayor.

## 5.6. Resumen del capítulo

La figura 5.15 muestra el diagrama global de la arquitectura cognitiva ARDIS que soluciona la tarea de *Diseño-Configuración-de-Inspección-de-Superficies*.

ARDIS está orientada a inspección de materiales laminados (acero inoxidable, madera, papel, plástico, etc.) y su base de conocimiento del dominio está organizada de forma que es posible acceder al conocimiento específico utilizado en cada inferencia. Las inferencias utilizan conocimiento genérico de inspección de superficies y éste es reutilizable. Así pues, uno de los objetivos ha sido identificar las características genéricas que permiten diferenciar distintos materiales laminados y sus defectos sobre la misma arquitectura ARDIS.



**Figura 5.15:** Diagrama global de la arquitectura ARDIS

Los puntos principales de la arquitectura ARDIS son:

- Se propone la arquitectura ARDIS para la solución de la tarea compleja de diseño-configuración de inspección de superficies.
- La tarea de inspección de superficies se descompone siguiendo el modelo de pericia de CommonKADS como una tarea de diseño-configuración, y se resuelve usando los PSMs Proponer-y-Revisar, Descomponer-Configuración-en-Etapas, etc.

- El cambio de algún requisito del sistema de inspección configura un nuevo sistema de inspección de la superficie en tiempo-real de reconfiguración.
- Las entradas y salida de la arquitectura ARDIS son:
  - La primera entrada son los requisitos de inspección de la superficie específica que los proporciona el inspector de línea y llegan a todas las inferencias necesarias de la arquitectura.
  - La segunda entrada es la imagen adquirida por el sistema físico de inspección que llega directamente a las inferencias de las técnicas de visión por computador.
  - La salida de la arquitectura es la configuración de un sistema de inspección de superficies que resuelve el problema de inspección de la superficie específica.
- Se modela la tarea de inspección de superficies y los métodos de resolución de problemas en el nivel del conocimiento. El conocimiento codificado en los roles estáticos de la arquitectura para solucionar el problema de inspección de una superficie específica se basa en reglas clásicas y/o borrosas.
- La estructura principal de la arquitectura ARDIS se compone de tres etapas:
  - La primera es la inicialización donde se configura y revisa un pequeño esqueleto inicial del sistema de inspección de la superficie, que sirve como base para la posterior extensión a un esqueleto más complejo que tiene en cuenta el resto de los requisitos: de entorno, de calidad, etc. La configuración inicial es muy rápida, y permite al sistema inspeccionar con esta configuración básica hasta que se configura el sistema completo.
  - La segunda es la extensión del esqueleto inicial, donde se configura un sistema de inspección que tiene en cuenta todos los requisitos específicos de la aplicación de inspección. La configuración es más lenta que en la

inicialización, pero el sistema se configura mejor debido a que se dispone de toda la información de la aplicación de inspección y se configuran todos los componentes del sistema.

- La tercera es la revisión del sistema completo de inspección de superficies configurado.
- El sistema configurado lleva a cabo la inspección de la superficie mediante las técnicas de visión por computador configuradas, que son específicas del problema de inspección de superficie concreto: segmentación, representación, descripción, reconocimiento e interpretación.
- Hay que diferenciar bien entre arquitectura cognitiva ARDIS y sistema configurado para inspección de la superficie:
  - La arquitectura cognitiva ARDIS es la estructura que soluciona la tarea de diseño-configuración de inspección de superficies y contempla la re-configuración del sistema de inspección de superficies en tiempo-real de la aplicación concreta.
  - El sistema de inspección de la superficie configurado es la solución al problema de inspección de la superficie específica. Esta configuración está formada por un conjunto de componentes de un sistema de inspección para una superficie específica.
- De forma general, se obtienen dos tipos de resultados: primero, un sistema de inspección de superficies configurado para el caso concreto, y segundo, una inspección de control de calidad de la superficie específica. Un sistema de inspección de superficies óptimamente configurado, para el caso concreto, mejora el control de calidad de la superficie.
- De esta forma, la arquitectura dinámica ARDIS permite reconfigurar un sistema de inspección para inspeccionar diferentes materiales laminados o diferentes defectos superficiales.





# Capítulo 6

## Entorno-aplicación para inspección de superficies SIVA II

### 6.1. Introducción

En esta tesis se ha desarrollado en el capítulo 4 un sistema óptico para inspección de superficies basada en iluminación láser y en el capítulo 5 una arquitectura basada en el conocimiento — ARDIS — que soluciona la *tarea Dinámica de Diseño-Configuración de Inspección de Superficies*. En este capítulo se implementan e integran estos dos desarrollos principales en el entorno-aplicación SIVA II, para la configuración de un sistema de inspección de superficies. El entorno-aplicación SIVA II es dinámico porque permite reconfigurar un sistema para inspeccionar diferentes superficies y automático/semiautomático debido a que la configuración la realiza el sistema a partir de los requisitos del sistema de inspección y la imagen adquirida.

El sistema configurado para inspección de la superficie concreta contempla una configuración básica inicial y una configuración completa teniendo en cuenta los factores de entorno, tiempo-real, calidad y técnicas de visión por computador. El sistema configurado como ejemplo en este capítulo, primero se configura para inspeccionar defectos de cascarilla residual en acero inoxidable, y segundo se reconfigura

para inspección de nudos superficiales en madera.

Por tanto, en este capítulo se ha desarrollado una aplicación orientada a dos propósitos: primero, implementar los métodos para solucionar la *tarea Dinámica de Diseño-Configuración de Inspección de Superficies* y sus inferencias manteniendo la estructura conceptual descrita en el capítulo 5 (arquitectura ARDIS), y segundo, generar una herramienta que se pueda utilizar para la adquisición y validación del conocimiento del experto a través del uso de ésta por el inspector de línea. Así, se ha definido un interfaz orientado a la aplicación particular de inspección de superficies (figura 6.1) que contempla los siguientes modos de operación del sistema:

1. Modo 1 “Funcionamiento en línea de inspección”. Este modo se selecciona al finalizar la configuración del sistema de inspección y muestra los resultados de inspección. Este modo lo utiliza el operador de inspección que se encarga de validar los resultados de inspección y decide en función de los defectos encontrados si es necesario limpiar o desechar el material laminado. El operador está continuamente en la cabina de inspección de la línea de producción y conoce el tipo de defecto a inspeccionar.
2. Modo 2 “Configuración automática del sistema”. Este modo configura de forma automática el sistema de inspección de superficies a partir de los requisitos seleccionados por el inspector de línea y la imagen adquirida. Este modo lo utiliza el inspector de línea que también conoce el tipo de defecto a inspeccionar y los requisitos necesarios para realizar la inspección del defecto. El inspector de línea se desplaza de una cabina de inspección a otra para configurar cada sistema de inspección.
3. Modo 3 “Configuración semiautomática del sistema”. Este modo configura también de forma automática el sistema de inspección de superficies, pero permite cambiar de forma manual los elementos de diseño o componentes seleccionados automáticamente. Este modo también lo utiliza el inspector de

línea y le permite variar los componentes configurados que considera convenientes.

4. Modo 4 “Introducir conocimiento al sistema”. Este modo lo utiliza sólo el usuario experto y permite introducir conocimiento que posteriormente utilizará la arquitectura ARDIS. La función del usuario experto en el proceso es previa a la configuración del sistema de inspección, pero también puede introducir o cambiar conocimiento en cualquier momento posterior.

Así pues, haciendo uso de la herramienta, se configura un sistema de inspección de superficies específico para cada caso concreto de superficie a inspeccionar, siguiendo los 4 pasos que se enumeran a continuación:

1. Primer paso — modo 4 —, fuera del entorno industrial, el usuario experto, introduce conocimiento genérico del dominio de inspección de superficies, para cada inferencia de la arquitectura.
2. Segundo paso — modo 2 ó 3 —, dentro de la industria, en el lugar de inspección. El inspector de la línea de producción, selecciona los requisitos específicos de la superficie a inspeccionar, por ejemplo, la forma del defecto, las características del entorno, el tipo de control de calidad, etc.
3. Tercer paso — modo 2 ó 3 —, se configura (primera vez) o reconfigura (posteriores veces) un sistema de inspección de una superficie completo, con todos los componentes de entorno, tiempo-real, calidad, etc. necesarios para cada caso de inspección.
4. Cuarto paso — modo 1 —, también dentro de la industria, en el lugar de inspección, el inspector de línea o el operario de inspección, observa los resultados de la inspección de la superficie y las estadísticas asociadas, y verifican que el sistema se ha configurado apropiadamente y que realiza bien la inspección de

la superficie. En el caso de que el sistema configurado no inspeccione correctamente, el inspector informará al usuario experto (encargado de introducir conocimiento al sistema) de las observaciones de mal funcionamiento que ha encontrado en el sistema.

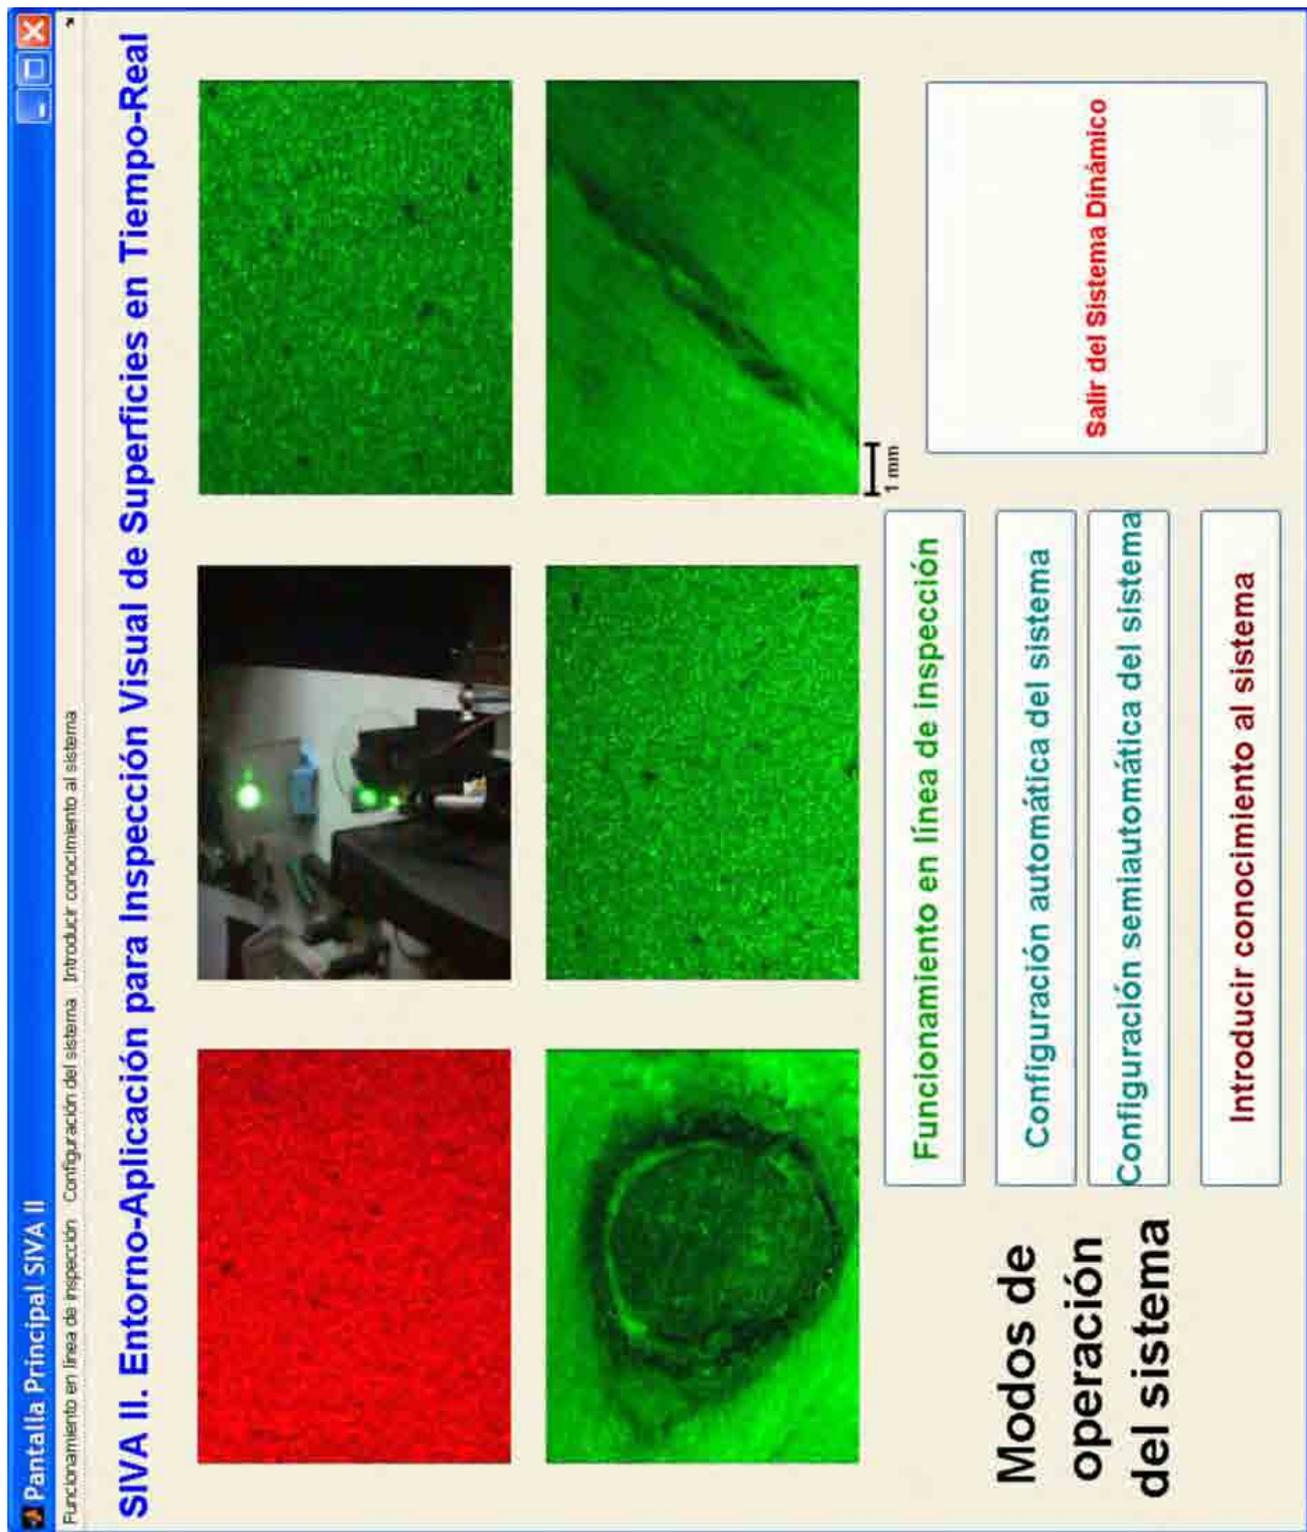
Así pues, el interfaz está orientado a la aplicación particular de inspección de superficies y a la interacción humano  $\iff$  entorno-aplicación  $\iff$  arquitectura (usuario experto, inspector de línea, operario  $\iff$  SIVA II  $\iff$  ARDIS).

La aplicación de interfaz ha permitido, en la fase de adquisición del conocimiento, que el usuario experto introduzca la base de reglas especializadas para cada inferencia. Además, la aplicación permite que el inspector de línea seleccione los defectos de interés sobre las imágenes de acero inoxidable, madera, etc. Durante el desarrollo del sistema, el modo semiautomático de esta aplicación sirve para que el experto evalúe e interaccione con los resultados parciales de configuración.

## **6.2. Implementación de la aplicación**

La implementación del sistema configurado se ha realizado en MATLAB, siguiendo la estructura conceptual desarrollada en esta tesis. La implementación se ha realizado sobre un ordenador PC pentium IV a 1,70 GHz. El sistema se ha desarrollado en MATLAB por razones de versatilidad de funciones de procesado de imagen y por ser un referente, en la fase de desarrollo, en la industria. En concreto MATLAB 7.0.1, que además, al ser un programa orientado a objetos, se pueden definir clases y estructuras y soportan la herencia de propiedades y métodos. Esto facilita la utilización de un amplio abanico de operadores de procesado de imagen (“Image Processing Toolbox version 5.0.1”), que pueden ser fácilmente configurados. Por otro lado, MATLAB está orientado al trabajo con matrices, por tanto, resulta muy útil su uso con imágenes 2D.

El desarrollo de la aplicación de interfaz, también, se ha realizado con MATLAB



**Figura 6.1:** Pantalla principal de la aplicación desarrollada para configurar el sistema SIVA II, y adquirir y validar el conocimiento del experto a través del inspector de línea

debido a la facilidad y el prototipado rápido que proporciona esta herramienta.

Por otro lado, la primera etapa o inicialización es la configuración del esqueleto inicial. Esta primera estructura forma la base para posteriormente ir añadiendo o quitando componentes hasta alcanzar un sistema óptimo de inspección de la superficie particular. Este sistema inicial permite inspeccionar rápidamente una superficie en la línea de producción mientras se va configurando (primera configuración) o reconfigurando (si varía la aplicación de inspección) de forma completa el sistema definitivo de inspección de la superficie. La situación de inicialización ocurre al inspeccionar una nueva superficie o al variar, el inspector de línea, los requisitos de inspección.

La base de conocimiento genérico de inspección de superficies que utiliza la arquitectura dinámica ARDIS se prueba en la configuración de dos sistemas de inspección, primero se configura un sistema para inspección de laminados de acero inoxidable, y segundo, se configura otro sistema para inspección de laminados de madera. Para la prueba, se han elegido estos dos materiales laminados y sus defectos por la diferencia entre las superficies, sus defectos y entorno de inspección. Esto demuestra la robustez de la base de conocimiento genérico que utiliza ARDIS frente a dos aplicaciones diferentes de inspección.

### **6.3. Funcionamiento en línea de inspección**

El modo de funcionamiento en línea de inspección (figura 6.2), permite por un lado validar el sistema configurado, y por otro lado, visualizar los resultados de inspección de la superficie concreta. Esta pantalla la utiliza el operario que supervisa continuamente el material laminado en la línea de producción y lleva a cabo el control de calidad del material laminado. Por ejemplo, en el caso de superar el límite permitido de defectos superficiales, el operario toma la decisión de pasar de nuevo el material laminado por el tren de laminación para intentar limpiarlo, previo

ajuste de los sistemas de limpieza.

Este modo presenta dos bloques de información, el de visualización y el de estadísticas. Primero, el de visualización que contiene:

- Imagen original (figura 6.2): visualiza la última imagen adquirida por el sistema en tiempo-real de inspección (en el caso que la adquisición sea elevada, por ejemplo 100 fps, sólo se muestra una cada segundo).
- Imagen segmentada (figura 6.2): visualiza la última imagen segmentada. Esto ayuda al operario a localizar rápidamente los defectos detectados por el sistema de inspección. En el caso, que la frecuencia de adquisición sea elevada y todas las imágenes contengan defectos, sólo se muestra una por segundo.
- Uniformidad de la iluminación (figura 6.2): visualiza en 3D la imagen adquirida. En el eje  $x$  e  $y$  se representa la imagen 2D y la coordenada  $z$  representa el nivel de gris asociado a cada píxel. Esto indica al operario si la iluminación de la superficie es uniforme, y por tanto, si los elementos de iluminación están funcionando apropiadamente. Esta información es muy útil para la buena utilización de los operadores de procesamiento de imagen, debido a que una imagen bien adquirida con iluminación uniforme agiliza la segmentación y evita la utilización de preprocesado. Por ejemplo, en el caso de configurar un sistema con iluminación láser, la detección de defectos es muy rápida y facilita el funcionamiento en tiempo-real debido a que los defectos se distinguen claramente en las imágenes, la iluminación es uniforme y se elimina el preprocesado.
- Columna del mínimo de la imagen — perfil — (figura 6.2): esta visualización es muy útil en inspección de defectos de cascarilla residual en planchas de acero inoxidable, porque muestra el mínimo nivel de gris en la imagen y su relación con los píxeles adyacentes. De esta forma, podemos observar en la figura 6.2 un pequeño valle entorno al mínimo de la imagen que significa que éste realmente pertenece a un defecto superficial. En el caso que el mínimo

apareciera en uno de los bordes y sin valle significaría que éste se debe a no uniformidad de iluminación o un fallo en la óptica. Por otro lado, también en el caso de cascarilla, podemos observar si el mínimo está dentro del rango característico de niveles de gris de la cascarilla residual.

El segundo bloque relativo a las estadísticas se compone por:

- Número de defectos en cada imagen (figura 6.2): este cálculo ayuda al operario a valorar el número de defectos que aparecen en cada imagen y si es necesario limpiar la superficie.
- % de defectos en cada imagen (figura 6.2): en el caso anterior se determina el número de defectos, pero en ocasiones resulta más útil conocer el % de superficie con defectos en una imagen. Por ejemplo, 10 pequeños defectos de 50 micras es menor defecto que un defecto de 1 mm.
- Área del mayor defecto (*micras*<sup>2</sup>) (figura 6.2): este cálculo, muestra el tamaño del mayor defecto en la imagen y ayuda a decidir el grado de gravedad de éste.
- Diámetro equivalente del mayor defecto (micras): en ocasiones resulta más útil disponer del diámetro equivalente, para igual que antes, decidir el grado de gravedad del defecto. Por ejemplo, en el caso de acero inoxidable, se establece el control de calidad en función de los diámetros.

## 6.4. Configuración automática del sistema

El modo de configuración automática (figura 6.3), configura de forma automática el sistema de inspección y sólo permite visualizar el proceso de configuración a través del menú desplegable *TareaDeConfiguraciónDeInspecciónSuperficial*. Este menú permite navegar por toda la estructura conceptual de la arquitectura ARDIS

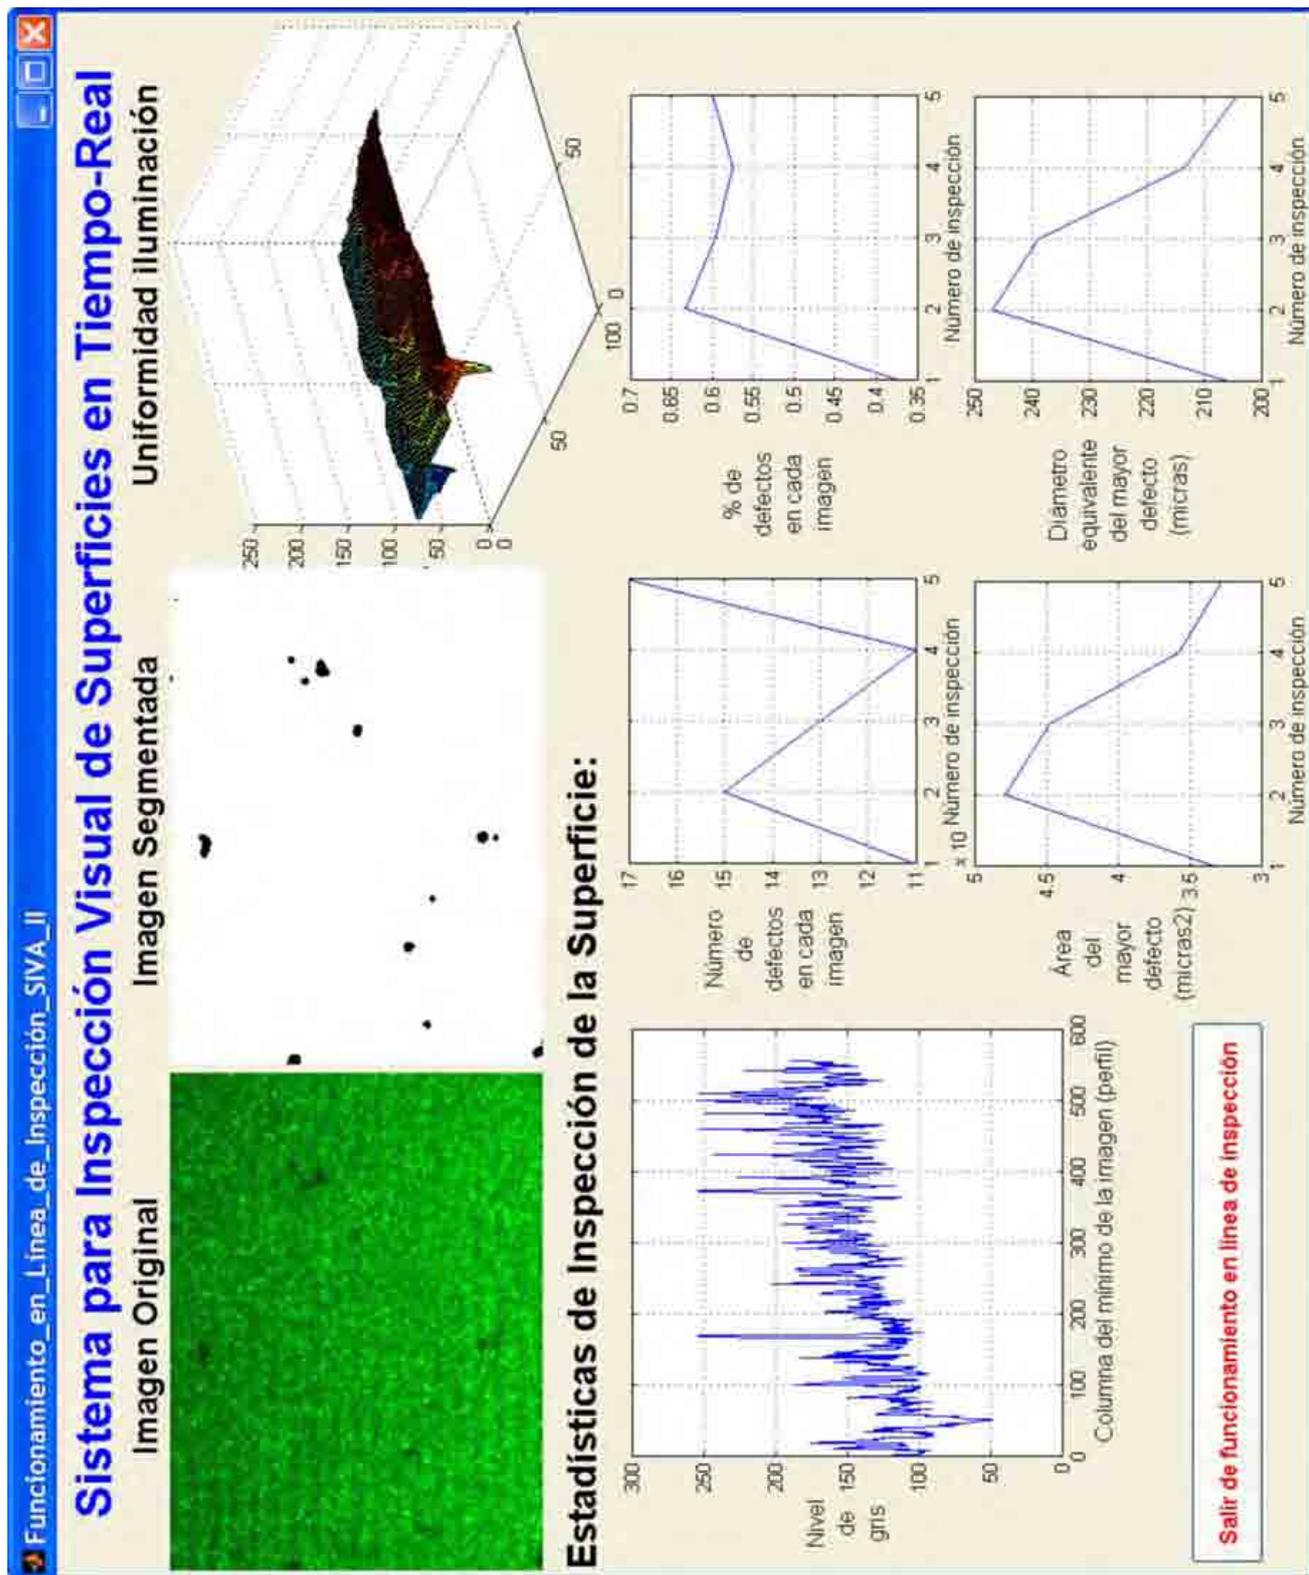


Figura 6.2: Pantalla del modo “Funcionamiento en línea de inspección” de la aplicación

descrita en el capítulo anterior y visualizar la traza de toma de decisiones realizada para configurar el sistema de inspección.

El modo de configuración automática del sistema permite al inspector de línea seleccionar los requisitos del sistema de inspección de superficies concreto. Estos requisitos, que se utilizan en este modo y en los dos siguientes, se dividen en cinco grupos:

- Requisitos Iniciales y Requisitos Globales (figura 6.3): los requisitos iniciales configuran el sistema inicial que es un sistema básico. El objetivo de este sistema que se configura rápidamente es doble: primero, permite configurar un pequeño sistema mientras se configura el sistema completo, y segundo, cuando sea necesario reconfigurar el sistema, se puede utilizar mientras esta configuración inicial.
- Requisitos Entorno (figura 6.3): los requisitos de entorno, son la entrada con las especificaciones relativas al entorno. Estos contienen la información, por ejemplo, de la [Velocidad de línea de producción], [Tipo de iluminación], etc.
- Requisitos Tiempo-Real (figura 6.3): los requisitos de tiempo-real, son muy útiles ya que especifican las necesidades de tiempo-real del sistema. A partir de estos requisitos, posteriormente se proveen las preferencias y restricciones relativas a tiempo-real para la configuración del sistema.
- Requisitos Diagnostico Calidad (figura 6.3): los requisitos de calidad, proporcionan las necesidades de control de calidad de la inspección a realizar. Dependiendo del tipo de material a inspeccionar, las restricciones pueden ser mayores o menores y esto influye directamente en las técnicas de visión por computador que se seleccionan para la inspección específica.
- Requisitos Técnicas Visión Artificial (figura 6.3): estos requisitos son muy útiles y ayudan a la selección de las técnicas de visión por computador más precisas para cada tipo de defecto. Es decir, por ejemplo, para detectar un

defecto circular las técnicas de visión por computador son distintas que para detectar un defecto rectangular.

La aplicación de interfaz para el modo de configuración automática del sistema, también contiene los siguientes módulos o facilidades:

- Imagen original (figura 6.3): visualiza la imagen que se utiliza para configurar el sistema (debido a que de la imagen se puede extraer información útil para el proceso de configuración).
- Imagen segmentada (figura 6.3): visualiza un resultado intermedio del sistema configurado. Esto facilita la evaluación en el proceso de configuración automática.
- Selección manual de la región del defecto (figura 6.3): permite al inspector de línea seleccionar sobre la imagen el defecto que quiere detectar. Esta información es muy útil porque se pueden extraer características sólo de la región del defecto que facilita la selección de las técnicas de visión por computador.
- Restaurar configuración por defecto (figura 6.3): en el caso que se realice una configuración inapropiada, siempre existe una configuración por defecto del sistema de inspección de superficies. Ésta puede restaurar una configuración poco eficiente, pero es muy rápida.
- Menús desplegables:
  - TareaDeConfiguraciónDeInspecciónSuperficial: como se comento anteriormente, permite visualizar el proceso de configuración automática
  - Configuraciones:
    - Añadir path: esto es muy útil en el caso de cambio de ordenador de inspección o cambio de disco duro o cambio de dirección de la aplicación, porque permite añadir la nueva dirección

- Guardar configuración: en ocasiones resulta muy útil guardar ciertas configuraciones que posteriormente se pueden recuperar de forma instantánea.
- Cargar configuración: esta opción nos permite recuperar alguna de las configuraciones almacenadas.

## 6.5. Configuración semiautomática del sistema

El modo de configuración semiautomática (figura 6.4), también configura de forma automática el sistema de inspección, pero permite de forma manual variar las decisiones que se van tomando en el proceso de configuración a través del menú desplegable *TareaDeConfiguraciónDeInspecciónSuperficial*. Este menú permite navegar por toda la estructura conceptual de la arquitectura ARDIS descrita en el capítulo anterior y cambiar manualmente la configuración de los elementos de diseño o componentes del sistema de inspección.

El modo de configuración semiautomática, también cuenta con el mismo conjunto de requisitos diferenciado por tipos que el modo anterior. Esto permite al inspector de línea seleccionar los requisitos del sistema de inspección de superficies concreto.

Además, la aplicación de interfaz para el modo de configuración semiautomática del sistema, también contiene los mismos módulos o facilidades que el modo automático.

## 6.6. Introducir conocimiento al sistema

El modo para introducir conocimiento al sistema (figura 6.5), permite añadir conocimiento de diferentes tipos (entorno, tiempo-real, etc.) del dominio de inspección de superficies, específico para cada inferencia. Así pues, permite completar o actualizar la base de conocimiento que configura el sistema de inspección de superficies. La

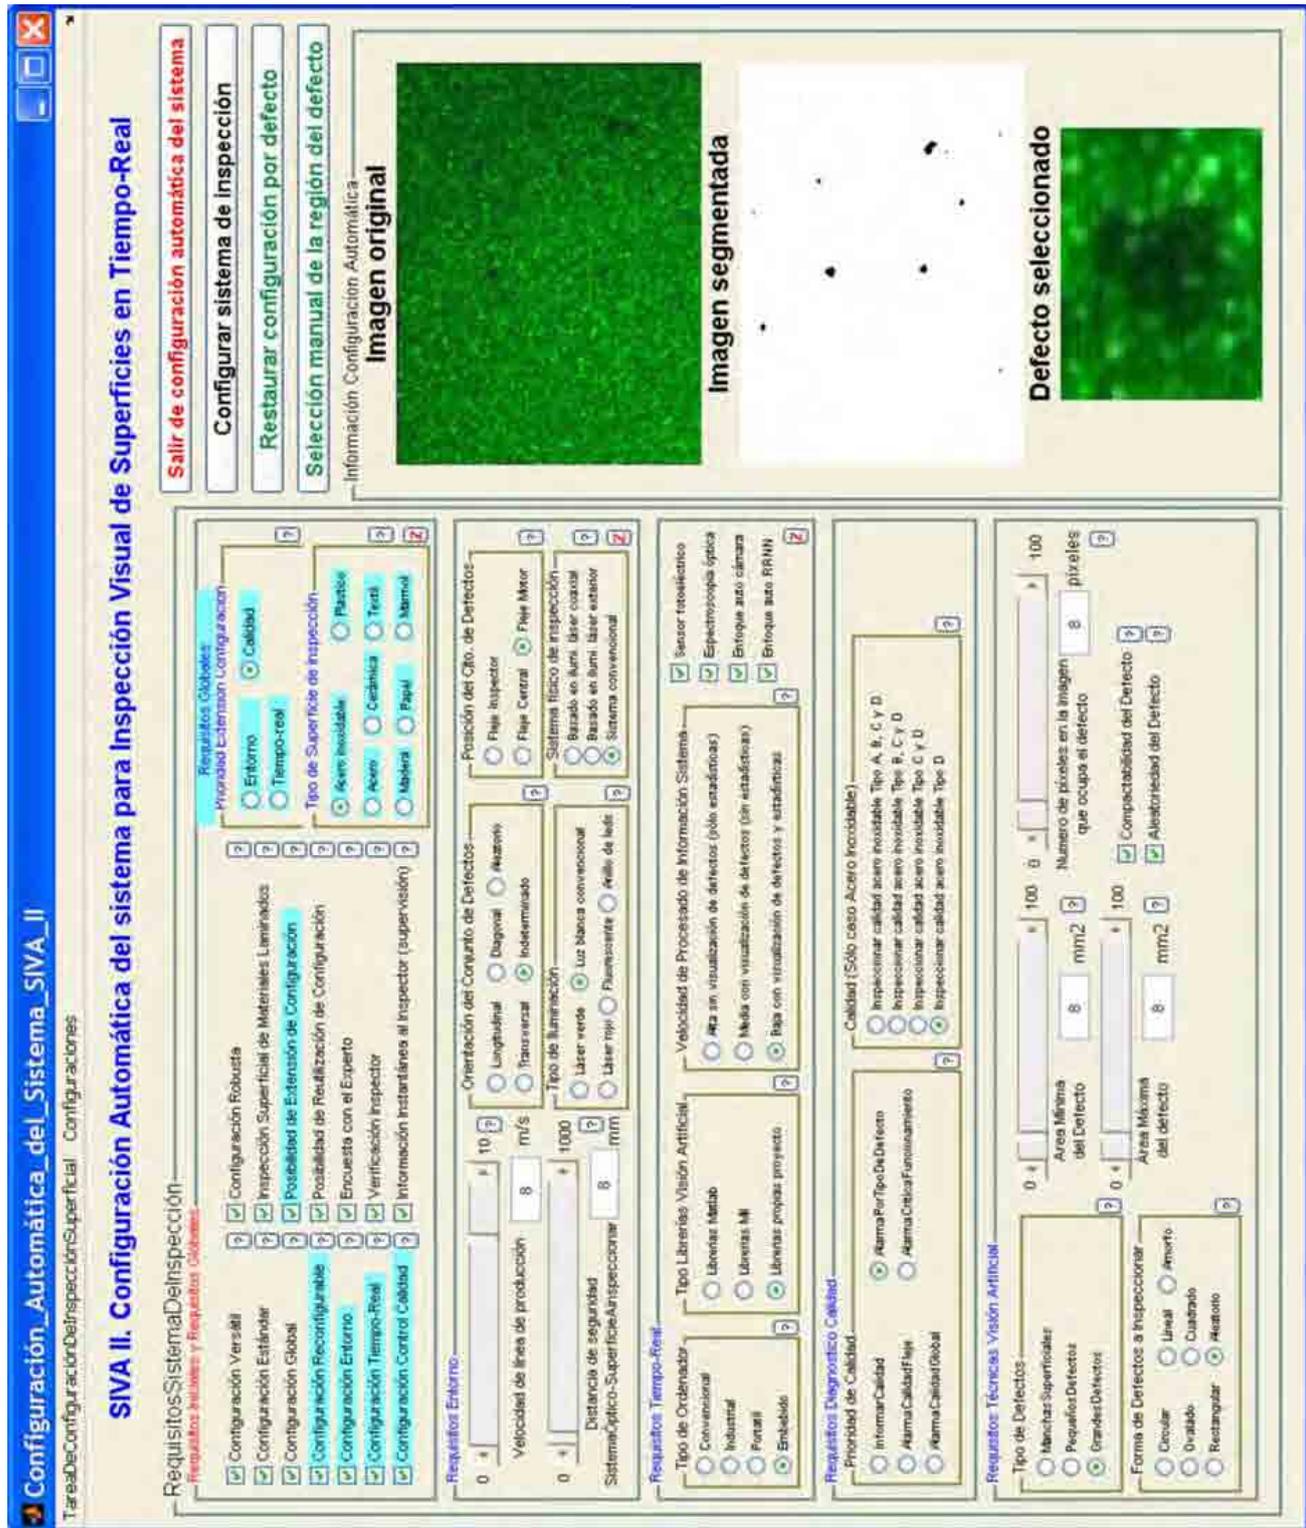


Figura 6.3: Pantalla del modo “Configuración automática del sistema” de la aplicación

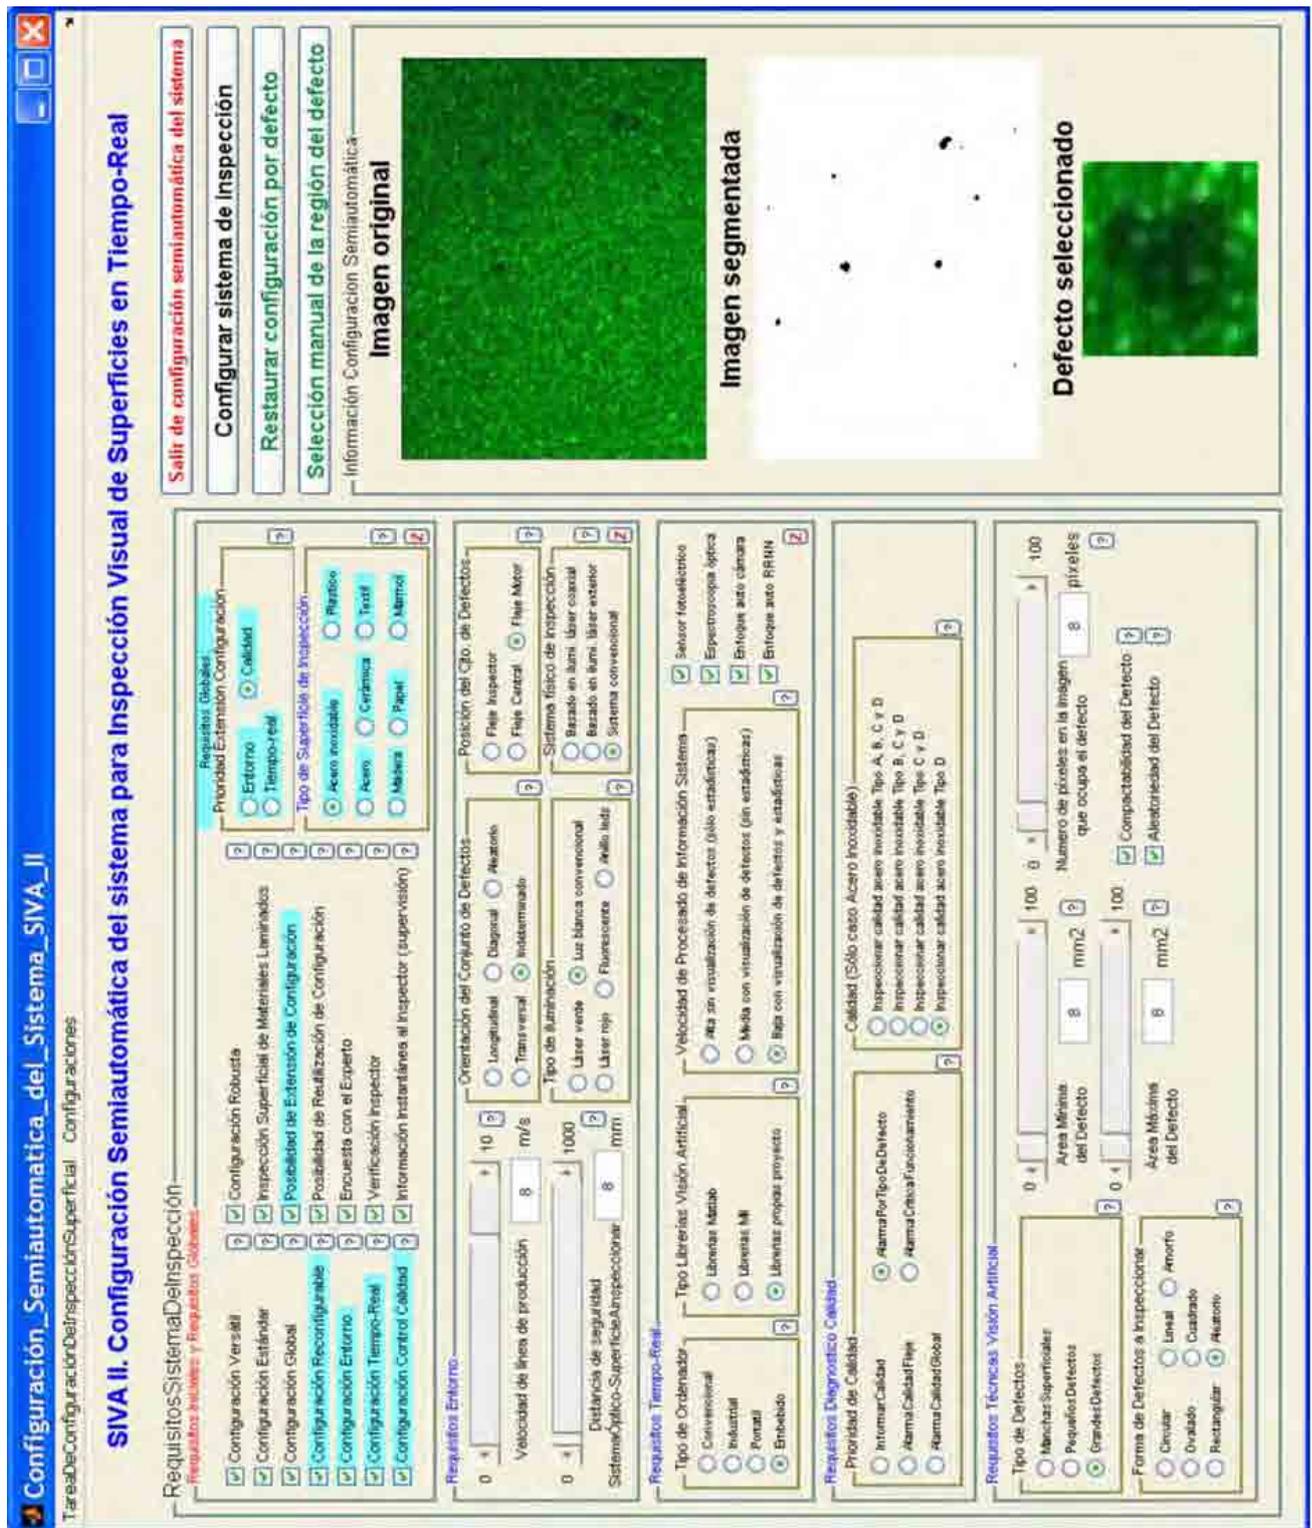


Figura 6.4: Pantalla del modo “Configuración semiautomática del sistema” de la aplicación

selección de la inferencia para introducir conocimiento, se realiza mediante el menú desplegable *TareaDeConfiguraciónDeInspecciónSuperficial*. Al igual que antes, este menú permite navegar por toda la estructura conceptual de la arquitectura ARDIS descrita en el capítulo anterior.

Por otro lado, la aplicación de interfaz para este modo también permite seleccionar los requisitos de inspección, de igual forma que en los modos anteriores. Esto permite al usuario experto seleccionar los requisitos del sistema de inspección de superficies concreto y observar su comportamiento junto con las reglas que introduce en la base de conocimiento.



# Capítulo 7

## Conclusiones y trabajo futuro

Los objetivos de esta tesis han sido el diseño y desarrollo de una arquitectura basada en el conocimiento para inspección de superficies de materiales laminados en entornos dinámicos, que se ha denominado ARDIS y se ha resuelto mediante la tarea compleja de diseño-configuración.

El trabajo aquí presentado ha tenido un origen experimental debido al volumen de la fase de adquisición de conocimiento del dominio, marcada por la detección y clasificación de defectos superficiales de cascarilla residual en planchas de acero inoxidable. Esto ha permitido diferenciar tipos de conocimiento genérico del dominio, que ha ayudado a generalizar para la inspección de otros materiales laminados como pueden ser madera, plástico, papel, etc. Los resultados experimentales obtenidos en la primera parte de la tesis no sólo han permitido adquirir el conocimiento del dominio que utiliza ARDIS, sino que también han permitido conocer la problemática actual asociada a la inspección de superficies, que se ha solucionado en la segunda parte de la tesis mediante un nuevo sistema de iluminación basado en láser y la arquitectura ARDIS.

Así pues, la segunda parte se ha validado experimentalmente implantándola en un sistema real que resuelve los problemas planteados por los métodos experimentales iniciales, y por tanto afrontando todos los problemas y la carga de trabajo que esto

conlleve.

## Principales aportaciones

Las aportaciones más importantes del presente trabajo se aglutinan en tres grandes grupos:

- El primero, relacionado con las contribuciones al área de inspección de cascarilla residual en la industria del acero inoxidable.
- El segundo, relacionado con las contribuciones al área de sistemas ópticos para inspección visual de superficies de materiales laminados.
- El tercer grupo de contribuciones está relacionado con la arquitectura ARDIS.

El primero, relacionado con las contribuciones al área de inspección de cascarilla residual en la industria del acero inoxidable, se puede resumir en los siguientes cuatro puntos:

1. Se ha realizado un estudio espectrofotométrico que muestra el rango de frecuencias óptimo para discriminar entre acero inoxidable y microdefectos de cascarilla residual, capítulo 3. Los resultados han permitido conocer que el rango de frecuencias óptimo está entorno a 550 nm. Así pues, la zona visible en torno al verde, presenta claras ventajas tanto en la diferencia de absorción óxido-acero inoxidable como en la relativa simplicidad de los sistemas a utilizar, que en inspección mediante cámara ha conducido a utilizar el plano de color verde de la imagen.
2. Se ha logrado la detección de cascarilla residual en línea de producción con cámara CCD mediante técnicas convencionales de adquisición, iluminación y procesamiento de imágenes.

3. Se ha conseguido la detección de cascarilla residual en línea de producción con sensor fotoeléctrico. Esta nueva técnica de detección alternativa ha sido capaz de resolver el problema de detección mediante sensores fotoeléctricos excitados por láser.
4. Se ha probado la detección de cascarilla mediante espectroscopia óptica de emisión espacio-temporal. En colaboración con el Instituto de Óptica del CSIC se ha planteado la aplicación de técnicas de espectroscopia diferencial de emisión, capaces de determinar con gran sensibilidad la naturaleza de una superficie a través de la evaporación de una cantidad mínima de material ( $< 10^{-5} \text{ mm}^3$  o  $< 0.1 \mu\text{g}$ ), mediante un pulso láser de alta potencia y corta duración, y analizando simultáneamente el material evaporado por espectroscopia óptica de emisión. Con este objetivo, se han realizado diversos ensayos preliminares con resultados satisfactorios.

El segundo, relacionado con las contribuciones al área de sistemas ópticos para inspección visual de superficies de materiales laminados, se puede resumir en los siguientes puntos:

1. Se ha diseñado, desarrollado e integrado un nuevo sistema óptico de iluminación difusa para inspección visual de superficies basado en una fuente láser puntual de elevada intensidad luminosa, que consigue iluminar eficazmente una pequeña superficie a inspeccionar para capturar imágenes con corto tiempo de exposición y poder trabajar en tiempo-real.
2. Se ha afrontado el diseño y desarrollo de un sistema físico de iluminación reutilizable, lo que ha permitido su utilización en inspección de diferentes superficies de materiales característicos de producción en línea y de sus defectos. Éste se ha validado experimentalmente en inspección de acero inoxidable con defectos superficiales de cascarilla residual e inspección de madera con diversos defectos superficiales: nudos, agujeros, grietas, pequeñas fisuras, manchas, etc.

3. Se ha solucionado el problema de adquisición óptima de la imagen en inspección de superficies a alta velocidad, cuyo origen estaba en la iluminación utilizada. Este método ilumina fuertemente una pequeña área de la superficie a inspeccionar y permite detectar desde microdefectos ( $\sim 50\mu m$ ) hasta pequeños defectos ( $\sim 5mm$ ), a alta velocidad. Además, esta solución ha satisfecho las restricciones de tiempo de exposición calculado en el capítulo 3.

Para lograr este cometido se ha diseñado y construido en el IAI-CSIC un banco óptico de pruebas, donde se han integrado los siguientes elementos: un láser de diodo de bajo coste, un difusor, varias lentes simples de buena calidad y una cámara (sin óptica) para captura de imagen. Esto permite investigar distintas disposiciones de las lentes, difusor y cámara para lograr una imagen óptima de la superficie a inspeccionar. En concreto, se implementan en el banco óptico dos arquitecturas de formación de imagen:

- La primera basada en iluminación láser difusa y coaxial con disposición de los elementos en forma de “T” y se ha utilizado un láser que emite en el rojo.
  - La segunda se basa en iluminación láser difusa formando un ángulo de 30 a 45° entre el eje óptico del sistema y el haz láser difuso, con disposición en forma de “V” y se han utilizado un láser que emite en el rojo y otro en el verde de alta luminosidad.
4. Este sistema óptico ha disminuido el esfuerzo en el preprocesado de la imagen, para mejorar la calidad de ésta. En inspección de superficies por computador es más eficiente obtener una buena imagen inicial que mejorar la imagen con preprocesado, debido a la extensa superficie que es necesario inspeccionar en una línea de producción. En el caso de inspección de microdefectos, el sistema óptico ha logrado una correcta formación de la imagen, que muestra los defectos y elimina fuertemente el preprocesado posterior de la imagen. También se ha conseguido no perder u ocultar información debido a sombras o

aberraciones de la óptica, entre otras.

5. Se ha conseguido inspeccionar microdefectos a alta velocidad con un corto tiempo de exposición y un elevado número  $F/\#$ , superando la contraposición que existe entre ellos. Así pues, el sistema láser diseñado ha permitido aumentar el número  $F/\#$  sin necesidad de aumentar el tiempo de exposición, debido a que el haz láser ilumina fuertemente la pequeña región a inspeccionar. Además, se ha favorecido el aumento de la profundidad de campo del sistema físico de inspección, hasta valores que evitan una imagen desenfocada frente a ondulaciones o pequeñas variaciones en el grosor de la superficie, y obedecer la restricción de distancia mínima de seguridad de inspección.
6. Se ha logrado una solución óptima para inspección en línea de producción de defectos superficiales, que es viable, sencilla y robusta para la industria de materiales laminados.
7. El conocimiento adquirido con estos experimentos ha contribuido a la diferenciación de tipos de conocimiento genérico del dominio de inspección de superficies que posteriormente utiliza la arquitectura ARDIS, capítulo 5.
8. La iluminación láser es robusta, pero ha presentado algunos problemas que se han ido solucionado, como el ruido “speckle” que se ha eliminado utilizando un difusor giratorio.

Recapitulando, se ha desarrollado un sistema óptico de iluminación difusa para inspección de superficies completamente operativo, en un escenario donde hay pocos sistemas que satisfagan las preferencias de inspección en distintos entornos pero que ofrece unos beneficios potenciales enormes, en el entorno industrial.

El tercer grupo de contribuciones está relacionado con la arquitectura ARDIS. En el presente trabajo, se muestra cómo el análisis de las aplicaciones de inspección de superficies parcialmente automatizadas existentes, esto es, de las características de las tareas, subtareas e inferencias que el sistema de inspección debe desempeñar

y de las restricciones de los entornos de trabajo existentes para inspección de superficies, ha conducido a formular un conjunto de requisitos esenciales. Estos requisitos fundamentan el desarrollo de la arquitectura basada en el conocimiento ARDIS, que tiene como finalidad lograr la configuración óptima de un sistema de inspección de una superficie específica en un entorno industrial, uno de los objetivos de esta tesis.

Por tanto, la arquitectura ARDIS, que se propone en esta tesis es una arquitectura jerárquica basada en conocimiento genérico de inspección de superficies, lo que permite la reutilización de conocimiento. Se trata de una arquitectura diseñada específicamente para inspección de superficies, lo que constituye uno de los aportes de esta tesis.

El diseño de la arquitectura sigue la metodología CommonKADS en todas sus facetas. Esta arquitectura busca lograr los principios básicos de modularidad, reusabilidad de conocimiento y facilidad de escalado e implantación en diferentes plataformas, considerando la tarea dinámica de inspección de superficies como una tarea compleja de diseño-configuración.

Las principales características de la arquitectura y sus implicaciones en la consecución del objetivo final, se resumen en los siguientes puntos:

1. La inspección de superficies es la tarea compleja que ha centrado esta tesis que, debido a la variabilidad del entorno de inspección, del control y supervisión de calidad, del tipo de defecto a inspeccionar, etc., requiere conocimiento del dominio para su solución y un análisis detallado que en este trabajo se lleva a cabo siguiendo la metodología CommonKADS.
2. La arquitectura ARDIS se ha basado en la idea principal de configurar en tiempo-real un sistema de inspección de superficies para cada caso particular de material laminado y de defecto a inspeccionar, esto es, para cada aplicación.
3. El sistema de inspección de superficies configurado está compuesto por un conjunto de componentes (elementos de diseño) y los parámetros de estos

---

componentes, ajustables en función del tipo de superficie inspeccionada.

4. ARDIS está orientada a inspección de materiales laminados (acero inoxidable, madera, papel, plástico, etc.) y su base de conocimiento del dominio está organizada de forma que es posible acceder al conocimiento específico utilizado en cada inferencia. Las inferencias utilizan conocimiento genérico de inspección de superficies y éste es reutilizable, ya que se puede utilizar en la configuración de diferentes sistemas de inspección. Así pues, uno de los objetivos ha sido identificar el conocimiento genérico que permite diferenciar distintos materiales laminados y sus defectos sobre la misma arquitectura ARDIS.
5. En ARDIS el conocimiento se codifica mediante reglas clásicas y reglas borrosas. Los roles estáticos del PSM son jugados por distintos tipos de conocimiento, en forma de reglas clásicas o borrosas.
6. La estrategia de configuración – esqueleto inicial y extensión del esqueleto inicial – se ha basado en una configuración básica inicial que ha permitido al sistema comenzar a inspeccionar hasta que se configura el sistema completo. En el caso de reconfiguración del sistema de inspección en tiempo real de la aplicación, el sistema puede configurar rápidamente un esqueleto inicial nuevo mientras se configura el nuevo sistema completo, sin necesidad de parar la inspección en la línea de producción (por ejemplo, una reconfiguración en tiempo real de la aplicación puede ser debida a la necesidad de inspeccionar otro tipo de defecto en el mismo material laminado). La estrategia que propone esta arquitectura aumenta considerablemente la capacidad de respuesta del sistema y la correcta consecución de los objetivos al no pretender la reconfiguración completa del sistema durante la inspección de la superficie sino configurar un sistema básico que permite continuar la inspección mientras se reconfigura el sistema completo.
7. El método borroso utilizado en la arquitectura ARDIS se basa en el método de Mamdani, donde se razona a partir de entradas numéricas y se obtiene una

salida numérica y lingüística (según el caso se puede utilizar una u otra). El resultado numérico sigue el método de Mamdani y se utiliza para configurar, por ejemplo, un parámetro numérico del sistema de inspección. El resultado lingüístico se basa también en el método de Mamdani, pero la salida se calcula mediante el máximo de cada función de pertenencia en el centro de masas global. Así, la función de pertenencia cuyo máximo sea el mayor en el centro de masas global, obtiene el resultado lingüístico de salida.

8. Se ha desarrollado una aplicación manteniendo la estructura conceptual descrita en el capítulo 5. Esta aplicación contiene, además, facilidades para la adquisición y validación del conocimiento del experto a través del uso de ésta por el inspector de línea. Así, se ha definido un interfaz orientado a la aplicación particular de inspección de superficies que contempla los siguientes modos de operación del sistema: Modo “Funcionamiento en línea de inspección”, Modo “Configuración automática del sistema”, Modo “Configuración semiautomática del sistema” y Modo “Introducir conocimiento al sistema”.
9. La arquitectura ARDIS ha sido validada con el entorno-aplicación para inspección de superficies SIVA II, tanto en tareas de configuración y adquisición de conocimiento como en inspección de acero inoxidable y madera, capítulo 6. La arquitectura propuesta ha permitido estas dos configuraciones diferentes para inspección de estas dos superficies, en un conjunto amplio de experimentos.
10. El diseño modular de la arquitectura ARDIS ha permitido la utilización de conocimiento del dominio para mejorar la configuración del sistema y la inspección de la superficie. La arquitectura ha sido diseñada para facilitar la futura incorporación de nuevo conocimiento genérico.
11. Se ha confirmado la utilidad del marco propuesto mediante la configuración de dos sistemas de inspección de superficies. El primero para inspección de cascarilla residual y el segundo para inspección de madera. Los resultados de inspección obtenidos por los sistemas configurados son buenos, pero se ha

llegado a la conclusión de que se necesita bastante conocimiento del dominio para conseguir una buena configuración del sistema de inspección. La mejora de los sistemas aquí configurados automáticamente frente a los comerciales es que utilizamos conocimiento del dominio, y podemos mejorar nuestro modelo inyectando más conocimiento genérico.

Resumiendo, en esta tesis se ha demostrado la utilidad de la metodología de los sistemas basados en el conocimiento para el análisis formal, en el nivel del conocimiento, de la tarea de inspección de superficies como tarea de diseño-configuración. Este análisis se ha realizado en tres niveles: tarea, método y conocimiento del dominio, y ha permitido diferenciar los tipos de conocimiento genérico en cualquier tarea de inspección de superficies, lo que ha permitido su reutilización en distintas aplicaciones.

## **Futuras líneas de investigación**

En cuanto a las líneas por las que se va a continuar la investigación realizada en esta tesis destacan las siguientes.

Por un lado, de forma inmediata se procederá a integrar el sistema óptico en una sola pieza que permitirá su utilización a gran escala dentro de la industria.

Por otro, partiendo del trabajo realizado en esta tesis y tomándolo como referencia la arquitectura ARDIS, se abren varias líneas de investigación:

- Extender los métodos de solución de la tarea.
- Completar los tipos de conocimiento genérico del dominio de inspección de superficies.
- Refinar el conocimiento que utiliza la arquitectura ARDIS.

- Mejorar la detección de defectos superficiales, añadiendo componentes que tengan en cuenta más conocimiento del dominio.
- Mejorar la aplicación que permite configurar el sistema de inspección a través del uso de ésta por el inspector de línea.

Una lección aprendida durante el desarrollo de esta tesis es que la adquisición de la imagen constituye un punto clave en el procesado de imagen posterior, de ahí que la incorporación en serie de este sistema de visión introduzca mejoras en las prestaciones actuales de los sistemas de inspección.

Sin duda la inspección de superficies tiene que confluir en un único sistema reconfigurable que sea capaz de inspeccionar los diferentes tipos de superficies laminadas, desde la inspección de acero inoxidable hasta la inspección de papel, madera, plástico, etc.

De este modo se evolucionará hacia sistemas de inspección genéricos con mayor grado de autonomía, con una interfaz de comunicación con el inspector de línea sencilla, intuitiva y eficaz que facilite la inspección de superficies en el entorno industrial con una intervención mínima.

Esta tesis constituye un paso hacia la inspección genérica de superficies laminadas, aumentando los beneficios potenciales, tanto económicos, como de reducción de riesgos para los humanos.

# **Apéndice A**

## **Comparación entre Perceptron**

### **Multicapa y Mapas**

### **Autoorganizados en inspección de cascarilla**

El objetivo de este apéndice es comparar la detección y clasificación de cascarilla residual en planchas de acero inoxidable mediante aprendizaje supervisado y no supervisado, y su utilización en el entorno-aplicación SIVA II. El primer caso se ejemplifica mediante el enfoque automático de una cámara para inspección de cascarilla residual en planchas de acero inoxidable (enfoque automático en función de la información extraída de la imagen). El problema de enfoque automático se ha elegido porque al tratarse de defectos pequeños, el enfoque automático propio de la cámara es incapaz de enfocar correctamente la imagen. El segundo caso se ejemplifica con la detección y clasificación de cascarilla residual. En ambos casos, el modelado de la imagen para la realimentación de los parámetros físicos de la cámara (autofoco) y la detección de cascarilla mediante aprendizaje no supervisado se realiza con Matlab. Las dos redes neuronales son apropiadas para funcionamiento

en tiempo-real de la aplicación de inspección de defectos superficiales.

## **A.1. Enfoque Automático**

### **A.1.1. Introducción**

El ajuste automático de foco es necesario debido a la dificultad que se plantea al enfocar una plancha de acero inoxidable a una distancia de inspección segura (esta distancia es un requisito configurable en el entorno-aplicación SIVA II). La distancia de inspección segura suele ser 30 cm entre la plancha de acero inoxidable y la cámara. A esta distancia de seguridad el autofocus de la cámara no es capaz de enfocar correctamente la plancha de acero. Así pues, se plantea la necesidad de un enfoque manual o un sistema capaz de enfocar la imagen automáticamente. Por otro lado, también es necesario un enfoque automático debido a las variaciones del entorno que rodea al sistema de inspección. Estas variaciones pueden ser debidas a distintos grosores en las planchas de acero (que ocasionan diferentes distancias entre la cámara y la superficie), cambios de iluminación, distintas reflectancias debido a los distintos tipos de acero inoxidable, etc. El problema dinámico se resuelve extrayendo información de las imágenes capturadas con la cámara (características). Las características se utilizan en una red neuronal que tiene como salida dos clases bien diferenciadas, imagen enfocada e imagen desenfocada.

Una vez enfocada correctamente la imagen se caracteriza la cascarilla residual y las características que la identifican. La imagen obtenida necesita algunas técnicas de preprocesado como filtrado espacial, ajuste de intensidad (contraste), etc.

La tarea de autoenfoco plantea distintas soluciones. Por un lado, el enfoque de la imagen a partir de la cascarilla residual presente en la plancha de acero. Pero, esta solución se descarta debido a que la plancha de acero no siempre tiene cascarilla residual y se podría estar variando el enfoque indefinidamente. La solución utilizada

es enfocar la imagen utilizando el grano natural del acero. Independientemente de la existencia de cascarilla en la planchas de acero. La tarea de autoenfoco puede ampliarse teniendo en cuenta el ajuste simultáneo del zoom y foco. Pero se descarta su implementación, debido a la introducción de complejidad en la red neuronal y que los resultados obtenidos variando el zoom manualmente no aportan mejoras en la adquisición de la imagen enfocada.

Por otro lado, para resolver la tarea de autoenfoco se analiza el vector de características y las clases de salida de la red neuronal. El vector de características de entrada a la red se optimiza de 36 a 9 características utilizando el método de Análisis de Componentes Principales (PCA). Las clases de salida inicialmente fueron tres; movimiento de foco hacia “foco cercano” (imagen desenfocada), movimiento de foco hacia “foco lejano” (imagen desenfocada) y parada de foco (imagen enfocada). Este planteamiento no entrena la red neuronal y es imposible minimizar la función de error entre las salidas de la red y los vectores de salida deseados. Esto se debe a que en una imagen desenfocada, a priori, no se sabe si hay que mover el foco hacia “foco cercano” o hacia “foco lejano” para enfocarla (siempre que la imagen se pueda enfocar). Por lo tanto, con este planteamiento no se pueden separar las clases de salida, movimiento hacia “foco cercano” (imagen desenfocada) y movimiento hacia “foco lejano” (imagen desenfocada).

El problema planteado en la topología de la red se resuelve mediante una solución empírica obtenida como fruto de la observación. La imagen se enfoca correctamente aplicando primero el autofocus de la cámara (la imagen no se consigue enfocar) y posteriormente movimiento manual del foco hacia “foco cercano” hasta que la imagen se enfoque. Este planteamiento utiliza dos clases de salida, movimiento de foco hacia “foco cercano” (imagen desenfocada) y parada de foco (imagen enfocada). En este caso, la red se entrena y permite diferenciar entre una imagen enfocada y desenfocada. La red clasifica las imágenes en enfocadas y desenfocadas, incluso cuando existen variaciones en la iluminación o variaciones en el acero.

## **A.1.2. Sistema de inspección y software utilizado**

### **A.1.2.1. Cámara**

El dispositivo físico de adquisición de imagen es una cámara de video color Mitsubishi CCD-300E. La cámara de video incorpora un CCD de 1/3" que contiene aproximadamente 440.000 píxeles efectivos, un autoenfoco y una óptica motorizada 8x (F1.8, f=6.5 – 52mm). Todas las funciones de la cámara pueden ser controladas a través del PC utilizando el puerto serie (RS-232C). Los parámetros que se pueden controlar de la cámara son los siguientes:

- White Balance: Auto/Lock/Outdoor/Indoor.
- Shutter Speed: 1/50, 1/120, 1/250, 1/500, 1/1000, 1/2000, 1/10000.
- Zoom: Auto/Manual.
- Foco: Auto/Manual.
- Iris: rango de iris [-30  $\iff$  +30].
- Bright: Controla el nivel de brillo de la imagen en la pantalla [-30  $\iff$  +30].
- Detail: Ajusta el contorno de la imagen [-30  $\iff$  +30].
- Color: Determina la intensidad del color [-30  $\iff$  +30].
- Tint: Ajusta la proporción Rojo/Verde [-30  $\iff$  +30].
- Back light: Controla el nivel de negro en la iluminación de fondo [-30  $\iff$  +30].
- Gain: Controla la ganancia del sensor [-30  $\iff$  +30].

### **A.1.2.2. Frame Graber**

La transferencia de la imagen, capturada por la cámara de video, al PC se realiza mediante un "Frame Graber" de Matrox Imaging. La tarjeta es una Matrox Meteor, que permite transferir imágenes al sistema en tiempo real. Las principales características son las siguientes:

- Captura NTSC/PAL/SECAM/RS-170/CCIR/ estándar RGB.

- “Frame Graber” PCI.
- Transferencia al PC en tiempo real.
- Video de alta calidad.
- Sincronización estable.
- Compatible con el siguiente software de Matrox Imaging: MIL-Lite/ActiveMil-Lite/Matrox Inspector/Intellicam

#### A.1.2.3. Librerías MIL

Las librerías Mil-Lite es un software de Matrox Imaging que permite adquirir y grabar imágenes/video en el PC, manipular datos, crear gráficos y controlar la visualización de imágenes/video en tiempo real en el PC.

#### A.1.2.4. Matlab

Matlab es un lenguaje de alto rendimiento para computación técnica. Éste integra computación, visualización y programación en un entorno fácil de usar; además de ser un referente para la industria por la variedad de funciones y métodos que soporta, en el diseño y desarrollo de un sistema o aplicación. Algunas características de Matlab son las siguientes:

- Calculo.
- Desarrollo de algoritmos.
- Adquisición de datos.
- Modelado y simulación.
- Análisis de datos y visualización.
- Gráficos.
- Desarrollo de interfaces de usuarios.
- Toolbox especializadas: Análisis de imagen, redes neuronales, ...

### **A.1.3. Ajuste automático de foco**

El ajuste automático de foco se realiza mediante una red neuronal. El tipo de red utilizado es un perceptron multicapa (MLP). Este tipo de redes han sido ampliamente utilizadas en visión artificial (tabla A.1).

El programa de autoenfoco se realiza en Matlab, utilizando la “Image Processing Toolbox” [Toolbox, 2004a] y la “Neural Network Toolbox” [Toolbox, 2004b].

El primer objetivo es extraer la información contenida en la imagen mediante el vector de características. Segundo, introducir esta información en la red neuronal para clasificar la imagen en la clase enfocada o desenfocada. Y finalmente realimentar la información hacia los parámetros físicos de la cámara. Es decir, si la salida de la red es la clase imagen desenfocada, hay que variar los parámetros físicos de la cámara hacia la imagen enfocada. Si, por el contrario, la salida de la red es la clase imagen enfocada, no hay que variar los parámetros físicos de la cámara.

#### **A.1.3.1. Red neuronal para autoajuste de foco**

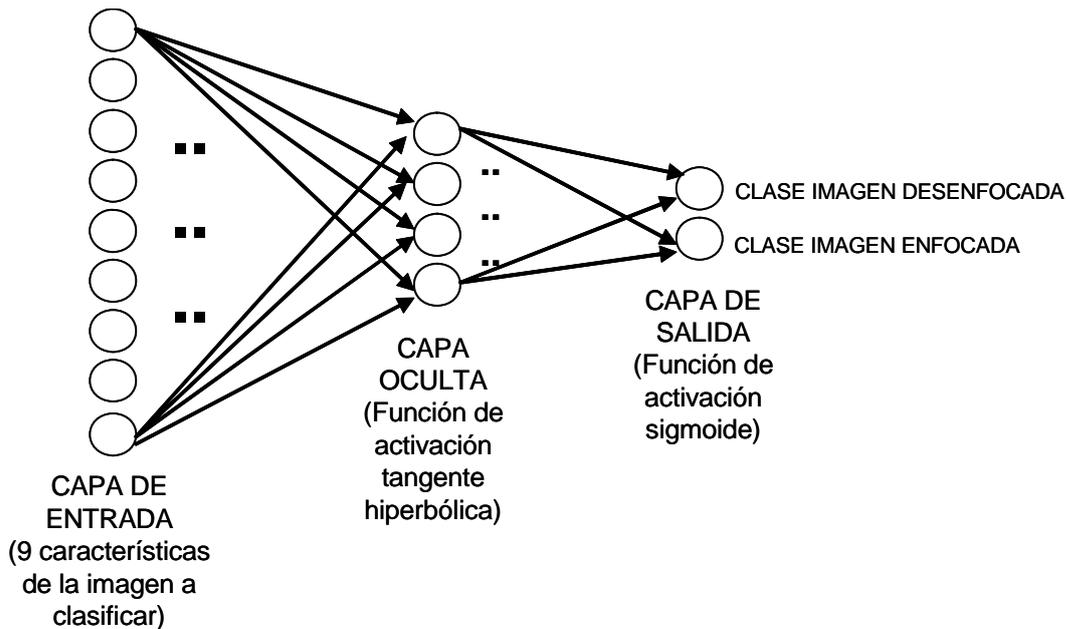
La función particular que realiza la red neuronal, propuesta para el ajuste automático de foco, es clasificar una imagen en enfocada o desenfocada. La red neuronal se entrena para que una entrada particular conduzca a una salida específica. Por lo tanto, una entrada característica de una imagen enfocada conducirá a una clase de salida de imagen enfocada y una entrada característica de una imagen desenfocada conducirá a una clase de salida de imagen desenfocada. La ventaja de la red neuronal es que frente a pequeñas variaciones en las características de entrada (pequeñas variaciones debido a la iluminación o tipo de acero), es capaz de seguir clasificando en imagen enfocada y desenfocada.

**A.1.3.1.1. Tipo de red** El tipo de red utilizada es un Perceptron Multicapa (MLP) con retropropagación del gradiente. Las funciones de activación más frecuen-

AUTORES	TIPO DE TAREA	DESCRIPCIÓN
[Venkatesh & Kumar Raja, 2003]	Clasificación de imágenes de satélite multispectrales	Entrenamiento de un perceptron multicapa usando datos recopilados in situ ó la salida de un programa de agrupamiento “K-means” ó ambos
[Raghu et al., 1995]	Clasificación de texturas	Red neuronal de dos etapas que combina las características de un mapa autoorganizado (SOM) y un perceptron multicapa (MLP)
[Agarwal & Chaudhuri, 1998]	Determinación de la orientación de un avión para un sistema basado en visión	Algoritmo de agrupamiento de Kohonen para dividir el espacio de características y perceptron multicapa para obtener las relaciones que existen entre cada clase de vectores de características y la correspondiente orientación del objetivo
[Pessoa & Maragos, 2000]	Reconocimiento de caracteres escritos a mano	El trabajo presenta la clase general de MRLNNs (redes neuronales multicapa Morfológica/Completa/lineal) y su algoritmo de entrenamiento
[Solberg, 2004]	Clasificación contextual no lineal	Estructura que integra modelos clásicos y recientes para clasificación de imagen. Desde un clasificador gaussiano multivariable hasta perceptrones multicapa, árboles de clasificación y modelos de regresión recientes
[Jung & Han, 2004]	Extracción de texto en imágenes en color complejas	Detección automática de texto en condiciones diferentes mediante perceptrones multicapa, sin etapa de extracción de características explícita
[Hu et al., 2002]	Clasificación de emociones faciales	Perceptron multicapa para clasificar un vector de características, en estados diferentes de un HMM (Modelo Oculto de Markov) de una secuencia de emociones
[Hakulinen & Hakkarainen, 1996]	Control de calidad en la fabricación de candados	Detección de defectos mediante un perceptron multicapa con una capa oculta
[Burel & Carel, 1994]	Detección y localización de caras en imágenes	Método basado en aprendizaje por ejemplo en una red neuronal. Un perceptron multicapa se usa para clasificación
[Douville, 2000]	Clasificación en tiempo-real de señales de tráfico	Perceptron de tres capas entrenado con propagación hacia atrás de errores, para clasificación

**Tabla A.1:** Recopilación de varios artículos donde el tipo de red utilizado es un perceptron multicapa (MLP)

tes en el perceptron multicapa son la función sigmoide y la tangente hiperbólica [Hu & Hwang, 2002]. En este caso, de forma empírica, se utiliza la función tangente hiperbólica en la capa oculta y la función sigmoide en la capa de salida. La función de error que se utiliza en la red neuronal MLP es el error cuadrático medio (mse). La figura A.1 muestra un diagrama de la red perceptron multicapa propuesta.



**Figura A.1:** Red neuronal MLP propuesta para clasificar la imagen de entrada en enfocada o desenfocada

La capa de entrada de la red neuronal se reduce de 36 a 9 neuronas (9 características de la imagen de entrada) utilizando la técnica de componentes principales (PCA). El número de neuronas de la capa oculta se calcula utilizando como referencia el conjunto de entrenamiento. El número de neuronas de la capa oculta está entre el 5% y el 10% del número de ejemplos de entrenamiento de la red neuronal. En este caso, el conjunto de entrenamiento está compuesto por 53 imágenes, entonces se ha elegido una capa oculta formada por 4 neuronas. La capa de salida está formada por dos neuronas que representan la clase imagen enfocada y la clase imagen desenfocada.

**A.1.3.1.2. Vector de características** El vector de características contiene las características que caracterizan una imagen y pueden pertenecer a dos clases: características de imagen enfocada y características de imagen desenfocada.

Las características tienen valores variables para una misma clase de imágenes, es decir se definen en un cierto rango. Por lo tanto, en el caso de una imagen enfocada, aunque la red no se entrene con todos los vectores de características que caracterizan una imagen enfocada, ésta es capaz de generalizar, aproximadamente, todas las imágenes enfocadas. El vector de características juega un papel muy importante en la solución de la tarea de clasificación con la red neuronal MLP, para autoenfoco de la cámara. Por consiguiente, a continuación se realiza un estudio detallado de las características que diferencian entre una imagen enfocada y otra desenfocada. Las características de una imagen desenfocada y enfocada se analizan en los tres planos de diferentes espacios de color.

Planos de color:

- Planos “Rojo”, “Verde” y “Azul” del espacio de color original RGB.
- Planos “Hue”, “Saturación” y “Value” del espacio de color HSV.
- Planos “Reflectancia”, “I (información del color)” y “Q (información del color)” del espacio de color YIQ.
- Planos “Reflectancia”, “Cb (plano Azul menos Y)” y “Cr (plano Rojo menos Y)” del espacio de color YCbCr.

Características estudiadas en cada plano de color:

- Umbral de detección de bordes utilizando el método de Sobel.
- Umbral de detección de bordes utilizando el método de Prewitt.
- Umbral de detección de bordes utilizando el método de Roberts.
- Umbral de detección de bordes utilizando el método de Laplaciana de la Gaussiana.
- Umbral de detección de bordes utilizando el método de Zero-Cross.
- Umbral de detección de bordes utilizando el método de Canny.

- Entropía de la imagen.
- Matriz de Co-ocurrencia.
  - Contraste.
  - Correlación.
  - Energía.
  - Homogeneidad.
- Media de la imagen.
- Desviación estándar de la imagen.
- Transformada de Fourier.
  - Media de la imagen transformada.
  - Desviación estándar de la imagen transformada.
  - Entropía de la imagen transformada.

El umbral calculado por los métodos de detección de borde de “Sobel”, “Prewitt”, “Roberts”, “Laplaciana de la Gaussiana”, “Zero-Cross” y “Canny” no han aportado información suficiente para diferenciar una imagen enfocada de otra desenfocada.

La entropía de la imagen es una medida estadística de la aleatoriedad. Esta medida puede usarse para caracterizar la textura de una imagen. La entropía se define por la siguiente ecuación:

$$Entropia = - \sum_{i=1}^{256} (p_i \log p_i)$$

donde  $p_i$  representa el número de píxeles de cada nivel de gris que contiene la imagen que se está analizando. La entropía tampoco diferencia correctamente entre una imagen enfocada y otra desenfocada.

La matriz de co-ocurrencia de una imagen es una transformación. La imagen en escala de grises se transforma a una matriz  $255 \times 255$ . La nueva matriz refleja el número de veces que coinciden horizontalmente y contiguamente dos píxeles del mismo valor. La figura A.2 muestra un ejemplo de una pequeña imagen  $5 \times 5$  y su matriz de co-ocurrencia.

Los análisis estadísticos que se realizan en la matriz de co-ocurrencia son:

- **Contaste:** es una medida del contraste de intensidad entre un píxel y su vecino, en toda la imagen.

$$\sum_{i,j} |i - j|^2 p(i, j)$$

- **Correlación:** es una medida de cómo está correlacionado un píxel con su vecino, en toda la imagen.

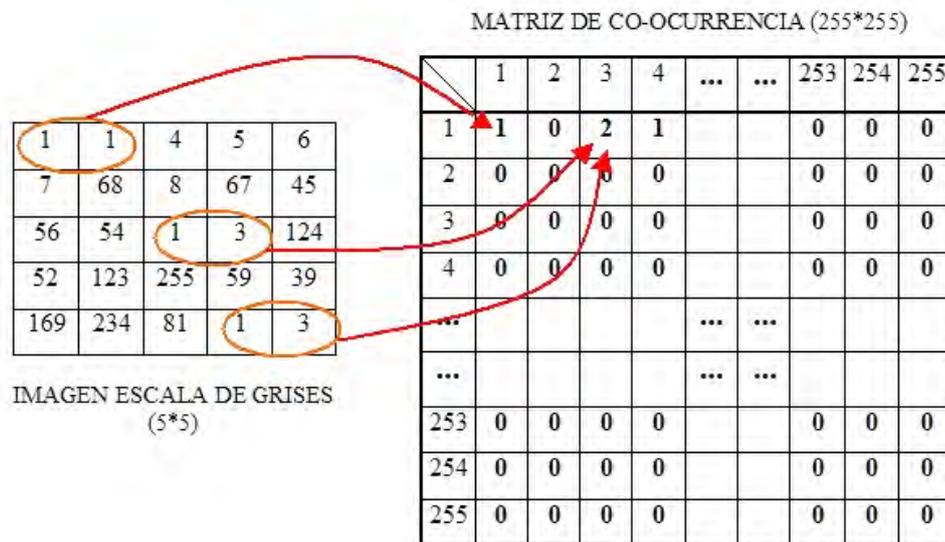
$$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j) p(i, j)}{\sigma_i \sigma_j}$$

- **Energía:** es la suma del cuadrado del valor de cada elemento de la matriz de co-ocurrencia.

$$\sum_{i,j} p(i, j)^2$$

- **Homogeneidad:** es una medida de la proximidad de la distribución de elementos en la matriz de co-ocurrencia a la diagonal de la matriz de co-ocurrencia.

$$\sum_{i,j} \frac{p(i, j)}{1 + |i - j|}$$



**Figura A.2:** Pequeña imagen en escala de grises y su matriz de co-ocurrencia

El único valor estadístico que diferencia entre una imagen enfocada y otra desenfocada es el contraste, utilizando el plano “Hue” del espacio de color HSV. El resto de

características no aportan distinción entre una imagen enfocada y otra desenfocada, en cualquier espacio de color.

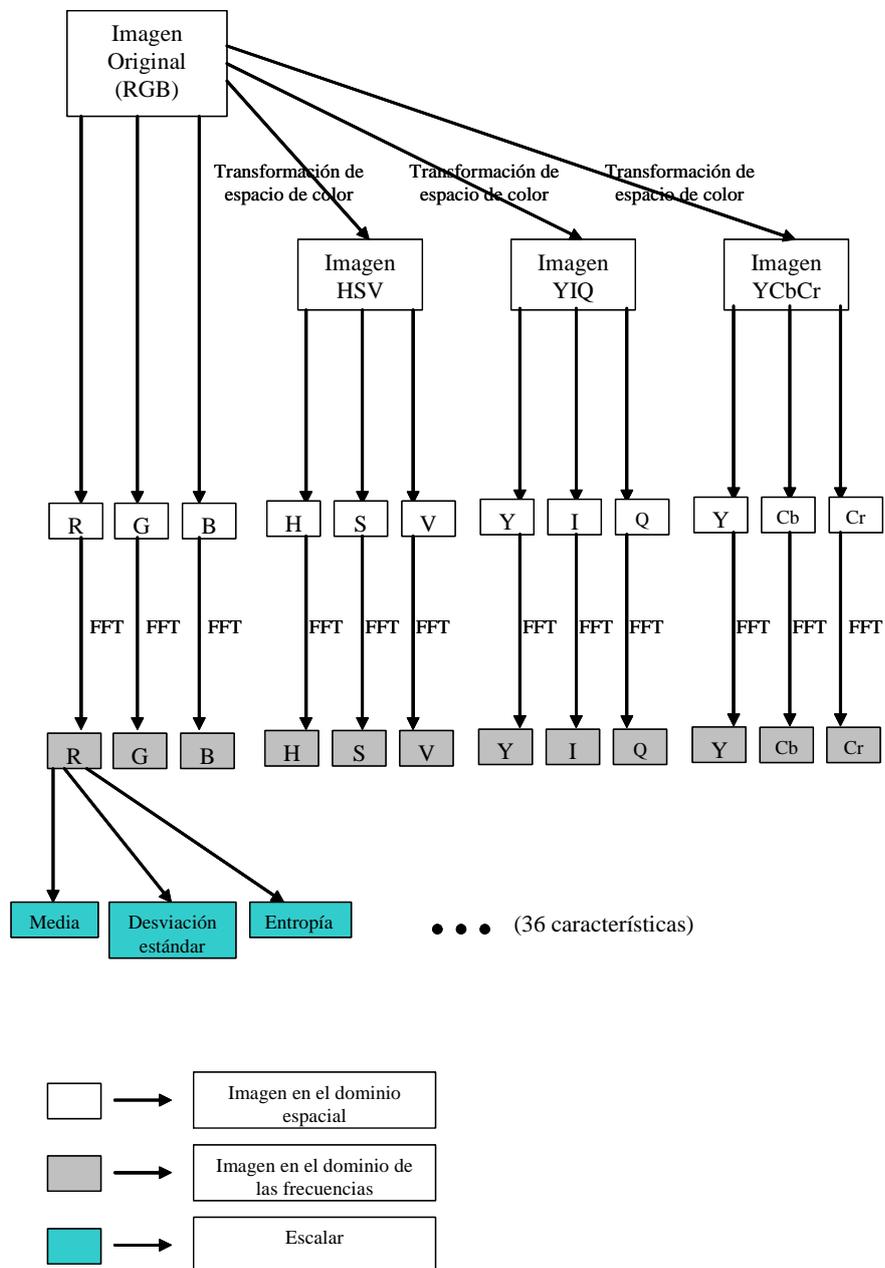
La media de la imagen calcula la media de todos los elementos de la matriz de la imagen en escala de grises. Así pues, se han calculado todas las medias de los tres planos de cada espacio de color en imágenes enfocadas y desenfocadas y no se han observado distinciones entre éstas.

La desviación estándar de la imagen es el cálculo de la desviación estándar de los elementos de la matriz de la imagen. También se han calculado todas las desviaciones estándar de todos los planos de los distintos espacios de color. Los resultados no han permitido diferenciar entre una imagen enfocada y otra desenfocada.

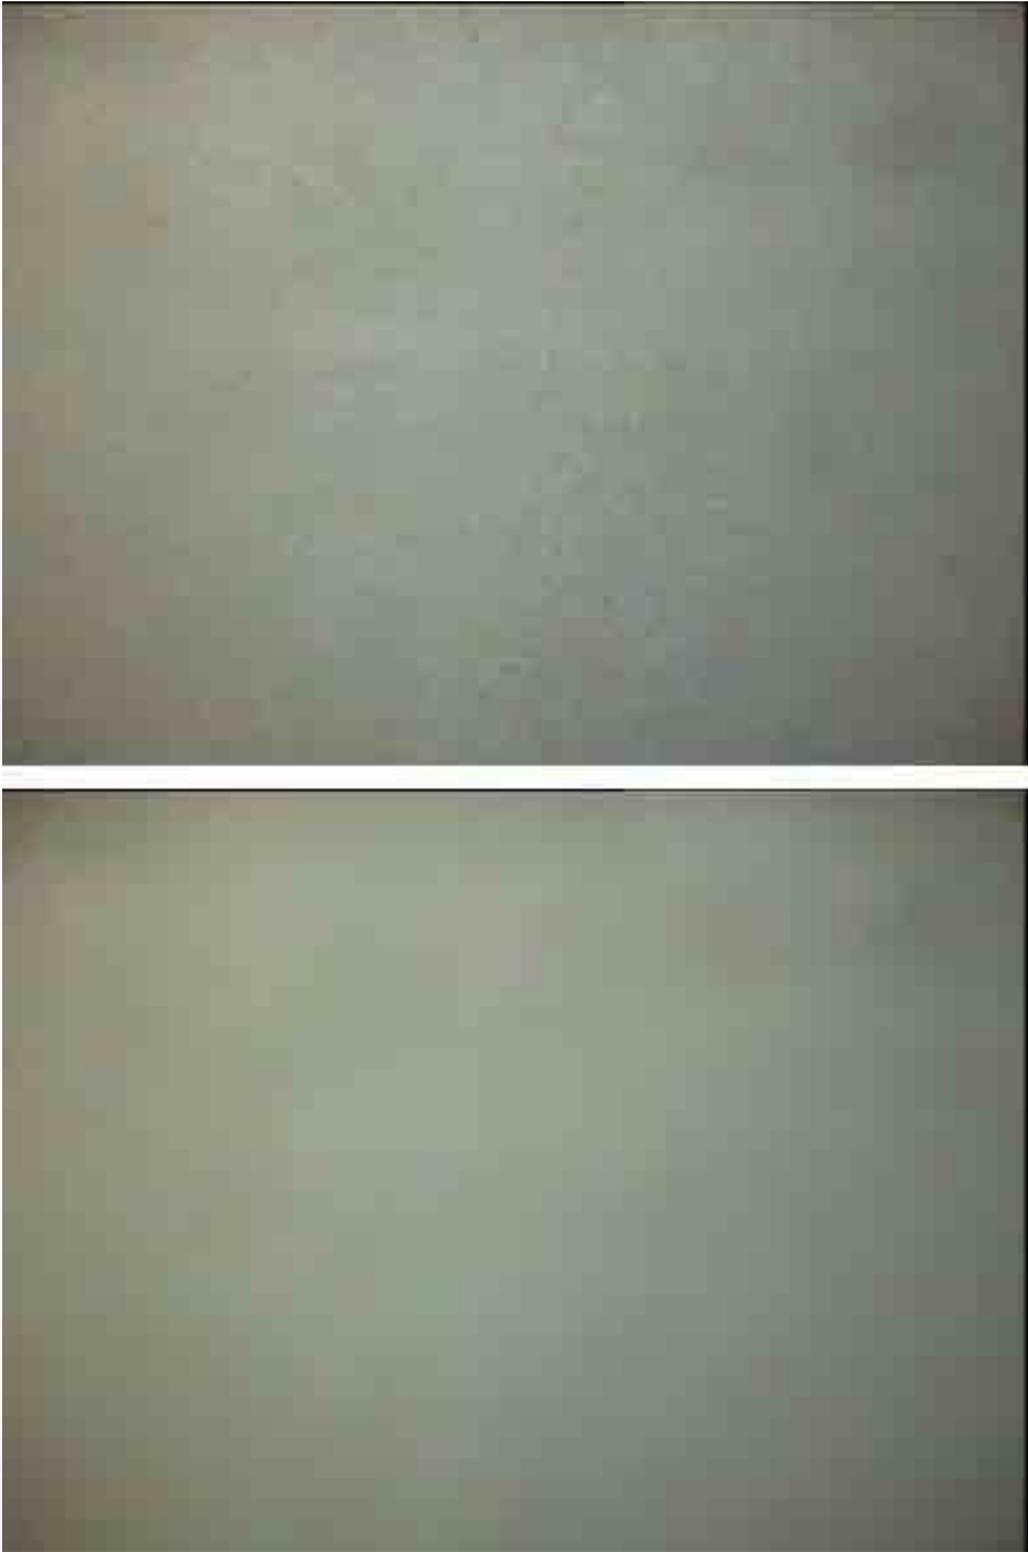
El último método utilizado para encontrar diferencias entre una imagen enfocada y otra desenfocada es la transformación a un espacio de frecuencias. Así, se pasa de un espacio normal a un espacio en frecuencias utilizando la transformada rápida de Fourier (FFT). Esta transformación es la que mejores resultados aporta. Primero se realiza la transformada rápida de Fourier de los tres planos de color de cada espacio de color. Segundo, en cada imagen transformada se calcula la media, la desviación estándar y la entropía. Con estas nuevas características si se observan diferencias entre una imagen enfocada y otra desenfocada. La figura A.3 muestra las 36 características que formarán el vector de características de entrada a la red neuronal MLP.

La figura A.4 muestra una imagen enfocada (a) y otra desenfocada (b) utilizadas en el estudio de las mejores características que las diferencia. Las figuras A.5 (a) y (b) reflejan la solución al problema, son las dos transformaciones al espacio de las frecuencias de los dos “planos de color rojo” espaciales de las imágenes A.4 (a) y (b) en el “espacio de color RGB”.

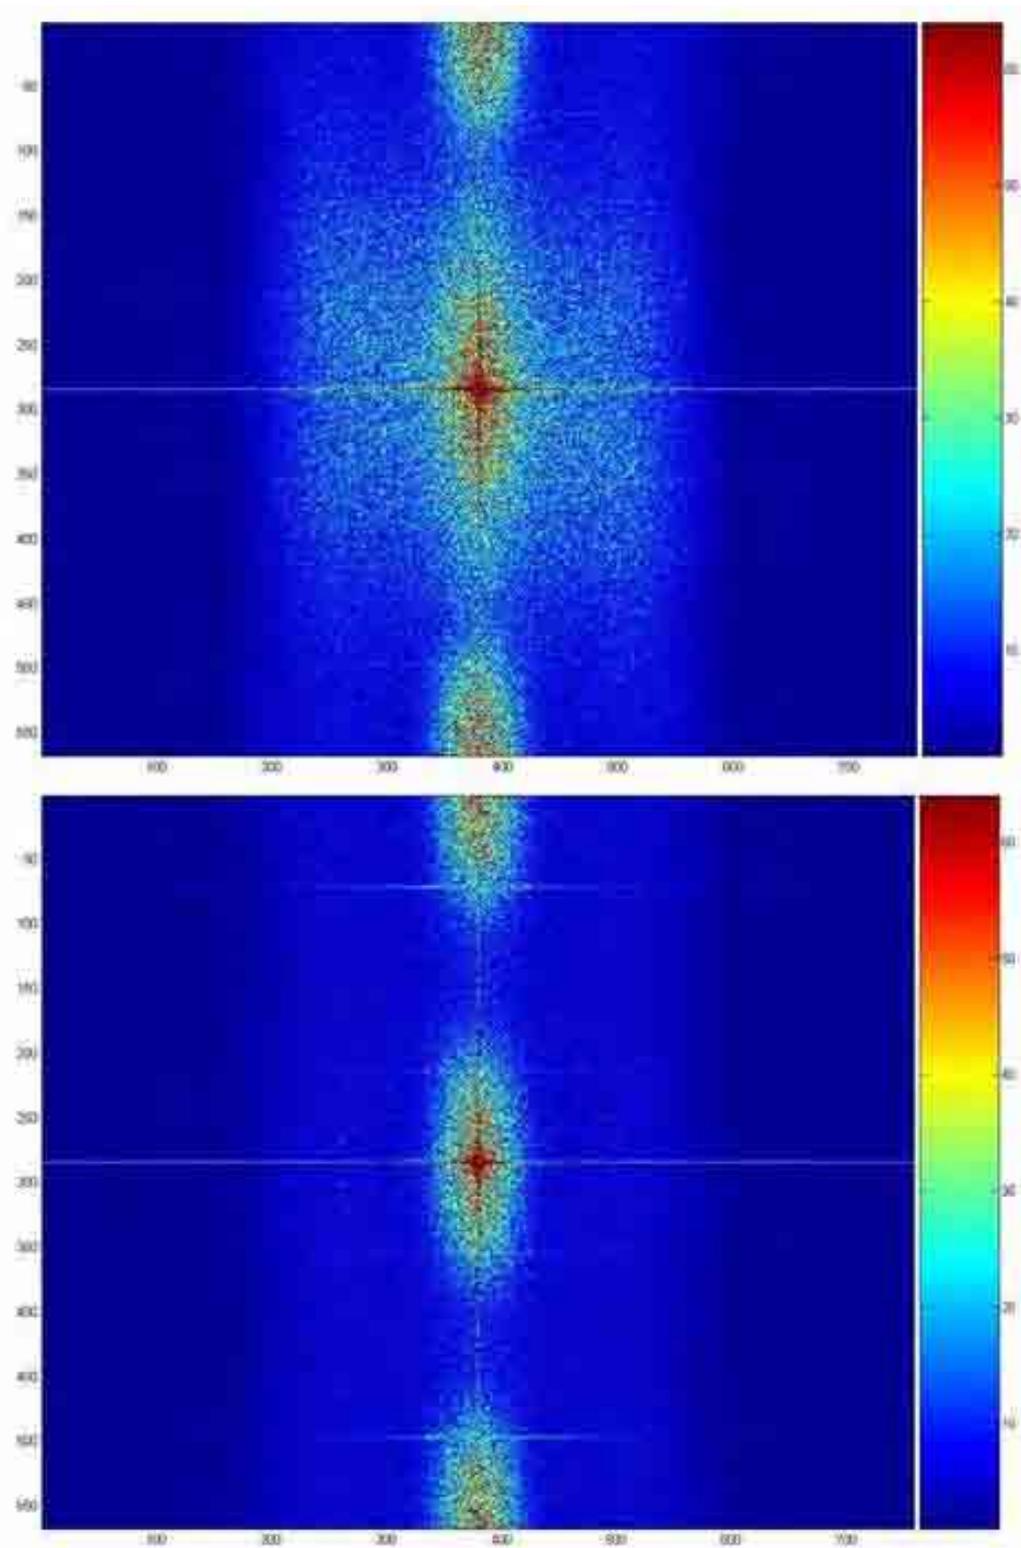
Finalmente, para reducir la dimensionalidad del espacio de entrada a la red neuronal se utiliza el método de Componentes Principales (PCA). Es decir, se eliminan las características redundantes. Así, después de aplicar el método al vector de 36



**Figura A.3:** Vector de 36 características de entrada a la red neuronal MLP, que es capaz de diferenciar entre una imagen enfocada y otra desenfocada



**Figura A.4:** (a) Imagen RGB enfocada, (b) Imagen RGB desenfocada



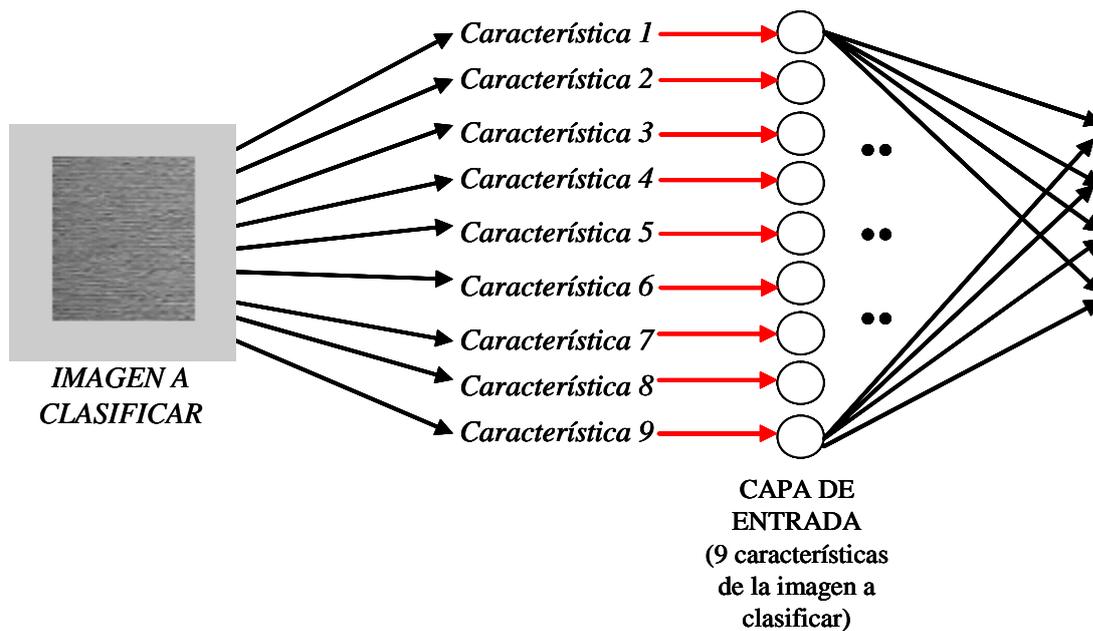
**Figura A.5:** (a) Transformada de Fourier del plano de color Rojo de la imagen RGB 4.4

(a), (b) Transformada de Fourier del plano de color Rojo de la imagen RGB 4.4 (b)

características, resulta que 27 características están correlacionadas y no aportan más información a la red neuronal, y sólo 9 características están sin correlacionar y son suficientes para diferenciar entre una imagen enfocada y otra desenfocada. Por tanto, las características se reducen de 36 a 9 debido a que los espacios de color están correlacionados entre ellos (el método PCA descubre eficazmente esta correlación).

**A.1.3.1.3. Capas de la red, entradas y salidas** Una vez analizadas las características, hay que crear la estructura de red neuronal MLP que resuelve este problema de clasificación. Las capas que forman la red se detallan a continuación:

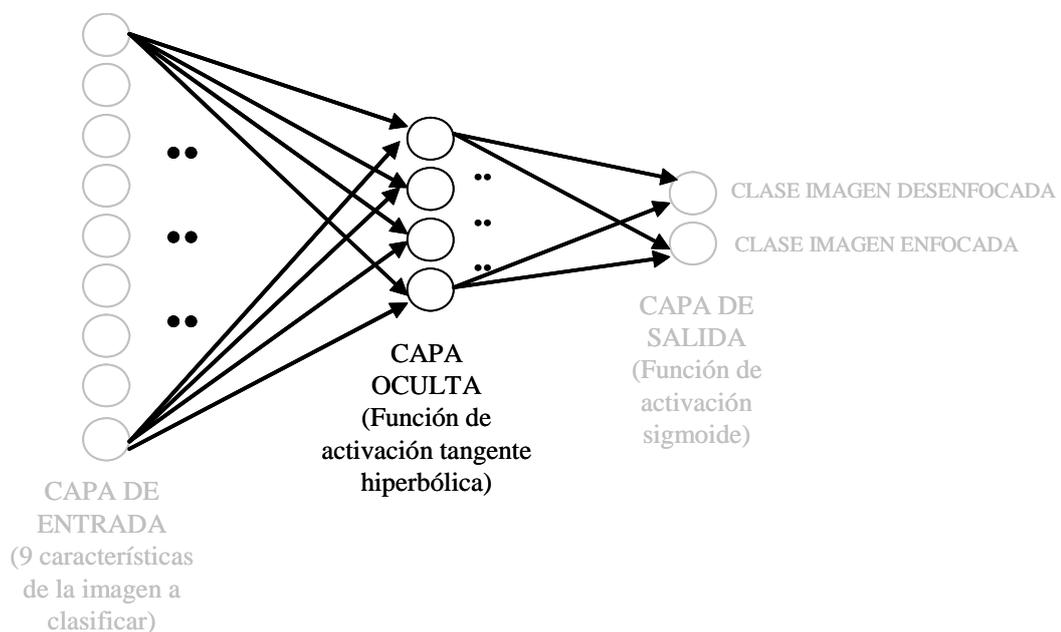
- Capa de entrada (figura A.6): compuesta por nueve neuronas debido a que hay 9 características que caracterizan la imagen a clasificar por la red neuronal.



**Figura A.6:** Capa de entrada de la red neuronal MLP

- Capa oculta (figura A.7): esta capa de neuronas con funciones de transferencia no lineales permite a la red neuronal aprender las relaciones entre los vectores

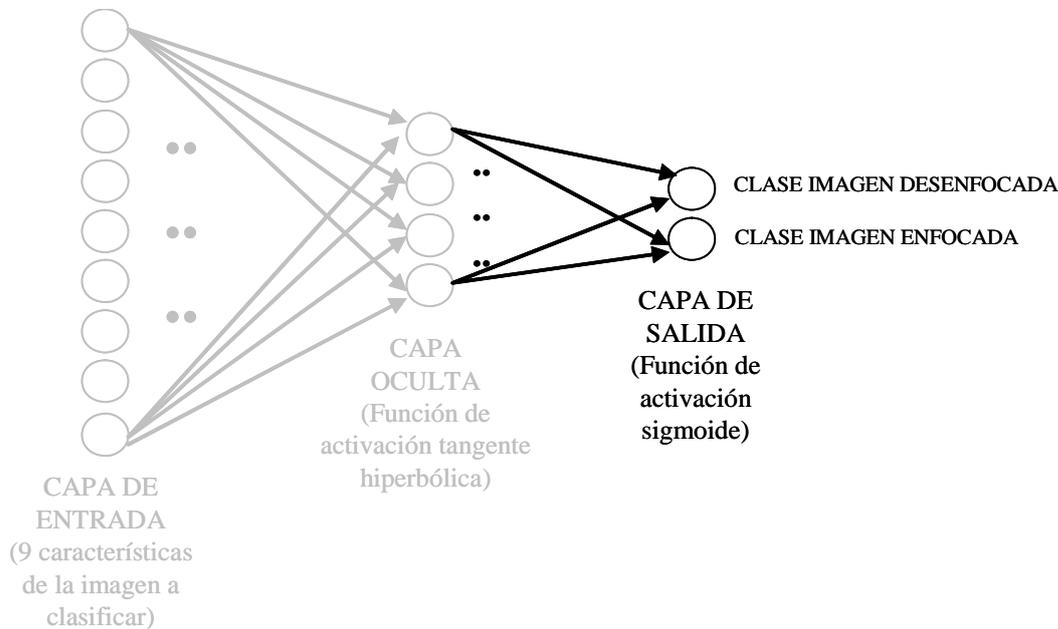
de entrada y salida. Las neuronas de la capa oculta de la red para resolver el problema de clasificación, utilizan la función de transferencia o de activación tangente hiperbólica. El número de neuronas de la capa oculta se ha calculado utilizando la regla siguiente: el número de neuronas de la capa oculta está entre el 5% y el 10% del número de ejemplos utilizados en el entrenamiento de la red. Entonces como el número de imágenes utilizadas en el entrenamiento ha sido de 53, se han elegido 4 neuronas para la capa oculta de la red.



**Figura A.7:** Capa oculta de la red neuronal MLP

- Capa de salida (figura A.8): esta capa define las clases de salida de la red neuronal. La red tiene que ser capaz de clasificar los vectores de entrada en la clase imagen enfocada o en la clase imagen desenfocada. Por otro lado, para obligar a las dos neuronas de la capa de salida de la red a responder en el rango  $[0, 1]$ , se ha elegido la función de transferencia o activación sigmoide. Así, si la imagen no está enfocada la salida de la red será 1 y 0; y si está enfocada la salida será 0 y 1. La capa de salida, también, se podía haber diseñado con

una sola neurona, donde la salida 0 hubiera indicado imagen no enfocada y la salida 1 hubiera indicado imagen enfocada.



**Figura A.8:** Capa de salida de la red neuronal MLP

**A.1.3.1.4. Conjunto de entrenamiento y prueba** El conjunto de entrenamiento está formado por 53 imágenes que generan 53 vectores de características para el entrenamiento de la red neuronal. El conjunto de prueba está formado por 36 imágenes. El conjunto de imágenes para probar la red es distinto al conjunto de imágenes para entrenar la red.

Las imágenes de entrenamiento y prueba se analizan manualmente una a una para clasificarlas en imagen enfocada o desenfocada. Esta información constituye el vector de salida de entrenamiento y prueba de la red. Así, en un fichero de texto se almacenan los vectores de salida de entrenamiento y en otro fichero de texto los vectores de salida de prueba.

El programa en Matlab, primero crea el vector de características de entrenamien-

to y lee el vector de salida del fichero de texto para entrenar la red. Segundo, crea el vector de características de prueba y verifica en el otro fichero de texto el correcto funcionamiento de la red.

### A.1.3.2. Entrenamiento de la red

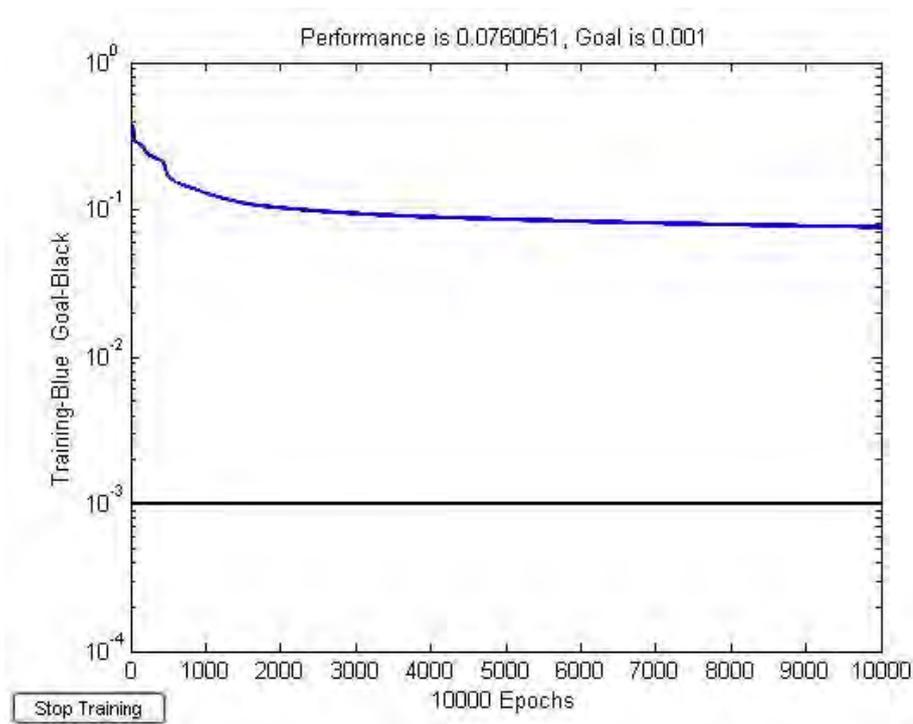
Una vez que se tienen los vectores de características de entrenamiento y los vectores de salida de entrenamiento, hay que inicializar los pesos y “bias” de la red neuronal. Después de la inicialización comienza el entrenamiento de la red. Durante el entrenamiento los pesos y “bias” de la red son ajustados para minimizar la función de error (error cuadrático medio). Es decir, minimizar el error cuadrático medio entre las salidas de la red y las salidas óptimas de entrenamiento.

El algoritmo de entrenamiento utilizado en este perceptron multicapa (MLP), usa el gradiente de la función de error para ajustar los pesos que minimizan la función de error. El gradiente se calcula mediante la técnica de retropropagación del gradiente, donde los cálculos se realizan a través de la red y hacia atrás de ella (de la capa de salida hacia la capa de entrada). Las expresiones de actualización de los pesos se obtienen derivando, teniendo en cuenta las dependencias funcionales y aplicando la regla de la cadena.

**A.1.3.2.1. Entrenamiento con tres clases de salida** Inicialmente se diseñó la capa de salida de la red neuronal con tres clases. El conjunto de imágenes de entrenamiento estaba formado por imágenes fuera de foco (“foco cercano” o “NEAR”), imágenes fuera de foco (“foco lejano” o “FAR”) e imágenes enfocadas. El vector de salida de entrenamiento reflejaba el conocimiento del enfoque manual. Es decir, en una imagen fuera de foco, con el “foco lejano”, había que mover el foco hacia “foco cercano” para poder enfocarla. Y viceversa, en una imagen fuera de foco, con el “foco cercano”, había que mover el foco hacia “foco lejano” para poder enfocarla.

Se entreno la red con este conjunto de entrenamiento y tres clases de salida. La

conclusión fue que la red se entrenaba incorrectamente. Así, al pasar el conjunto de imágenes de entrenamiento, después de entrenar la red con esas mismas imágenes, la respuesta de la red no daba los resultados esperados. La grafica que visualiza la minimización del error cuadrático medio se observa en la figura A.9, después de 10000 ciclos de entrenamiento.



**Figura A.9:** Error cuadrático medio después de 10000 ciclos de entrenamiento

El problema se debe a que en el cálculo del vector de salida se utiliza conocimiento propio del diseñador. Éste conoce, a priori, si la imagen está fuera de foco en un “foco cercano” o “un foco lejano”. Sin embargo, en el entrenamiento de la red esta información se desconoce y no se puede extraer de la imagen. Una imagen fuera de foco en un “foco lejano” es igual a una imagen fuera de foco en un “foco cercano”. Sin conocimiento a priori, no se puede clasificar una imagen en desenfocada en un “foco cercano” o desenfocada en un “foco lejano”.

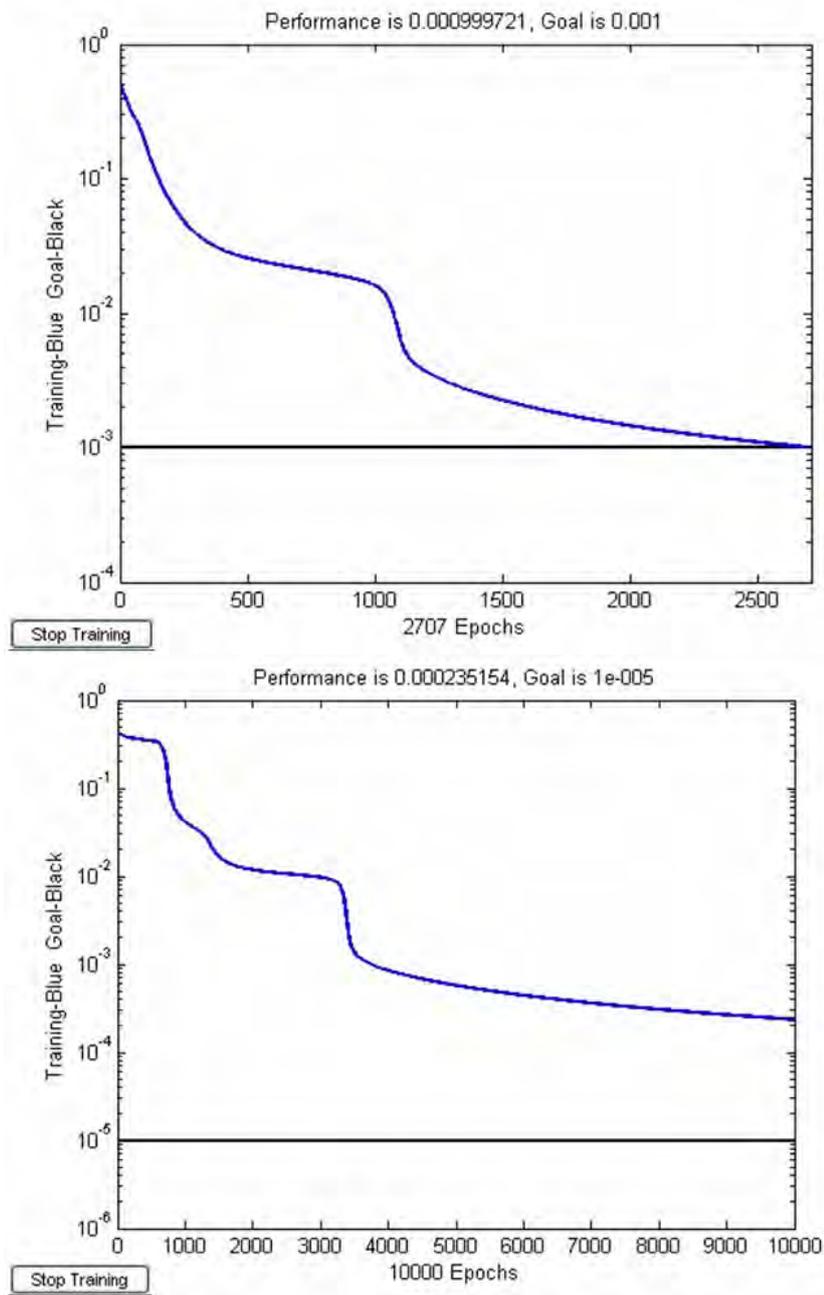
**A.1.3.2.2. Entrenamiento con dos clases de salida** La solución al problema es reducir la dimensionalidad del espacio de salida a dos clases, basándonos en la solución empírica comentada anteriormente. La clase imagen enfocada y la clase imagen desenfocada. En este caso, el entrenamiento de la red neuronal MLP se realiza correctamente. La clase imagen desenfocada representa todas las imágenes desenfocadas fuera de foco en un “foco lejano” y fuera de foco en un “foco cercano”. La clase imagen enfocada representa las imágenes enfocadas.

El entrenamiento se realiza primero con objetivo de error 0,001 y segundo con objetivo de error  $1e-5$ . La figura A.10 (a) visualiza la grafica de minimización de error cuadrático medio con objetivo de error de 0,001, después de 2707 ciclos de entrenamiento y A.10 (b) con objetivo de error de  $1e-5$ , después de 10000 ciclos de entrenamiento.

### **A.1.3.3. Prueba de la red**

El siguiente paso es probar el funcionamiento de la red con un conjunto de imágenes de prueba. Estas imágenes son distintas a las del conjunto de entrenamiento. En la prueba de la red se tienen los vectores de características de las nuevas imágenes y los vectores salida óptimos con la clasificación correcta de las imágenes de entrada en enfocadas o desenfocadas. Pero, a diferencia de la fase de entrenamiento, ahora los vectores salida óptimos sólo se utilizan para comprobar que la red funciona correctamente. Es decir, se introducen los nuevos vectores de características en la red y se observan las salidas de dicha red; si las salidas coinciden con el vectores salida óptimos implica que la red funciona correctamente, si por el contrario difieren la red no funciona bien. El conjunto de imágenes de prueba está formado por 36 imágenes enfocadas y desenfocadas.

Los resultados de clasificación, obtenidos con la red MLP, son casi totalmente correctos (97,2%) y demuestran que el perceptron multicapa entrenado es capaz de clasificar una imagen en enfocada o desenfocada. A pesar de existir pequeñas



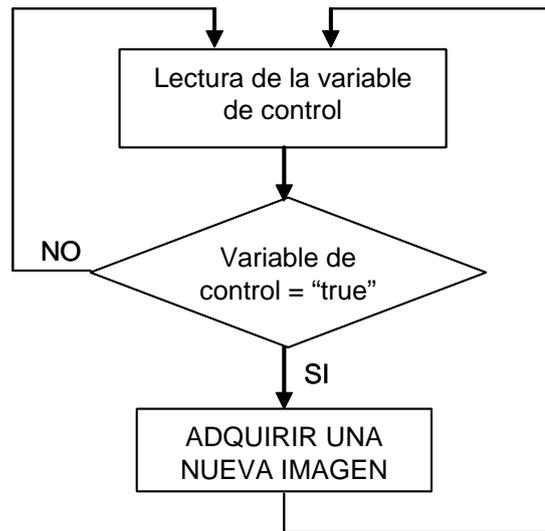
**Figura A.10:** (a) Error cuadrático medio después de 2707 ciclos de entrenamiento (objetivo de error 0.001), (b) Error cuadrático medio después de 10000 ciclos de entrenamiento (objetivo de error  $1e^{-5}$ )

variaciones debido a la iluminación exterior y la posición de la cámara.

#### **A.1.3.4. Programa en C++ para adquisición de imagen**

El objetivo final es utilizar en el entorno-aplicación SIVA II el sistema de autoenfoco con red neuronal MLP, es decir, utilizarlo en el sistema de inspección en el caso que lo configure el inspector de línea. Este modulo de autoenfoco se compone de un programa de control de adquisición de imagen, la clasificación de la imagen (con la red MLP) en enfocada o desenfocada y finalmente, si la imagen no está enfocada, la realimentación de los parámetros físicos de la cámara hasta conseguir enfocar la imagen.

El programa de adquisición de la imagen realizado en C++ utiliza las librerías MIL Lite de Matrox Imaging. El algoritmo de control adquiere imágenes cuando un programa externo se lo indica. El programa en C++ es un programa esclavo (bucle infinito), que recibe una variable de control de un programa maestro en Matlab a través de un fichero de texto. Si el fichero contiene la variable de control “true”, el programa adquiere una imagen para analizarla con el sistema de autoenfoco. Si el fichero contiene la variable de control “false”, el programa no adquiere imágenes y se queda en estado de latencia comprobando cada segundo el estado de la variable de control. La siguiente figura A.11 muestra el diagrama de flujo del algoritmo.



**Figura A.11:** Diagrama de flujo del programa de adquisición de imágenes

#### **A.1.3.5. Funcionamiento continuo de autofocus en tiempo-real**

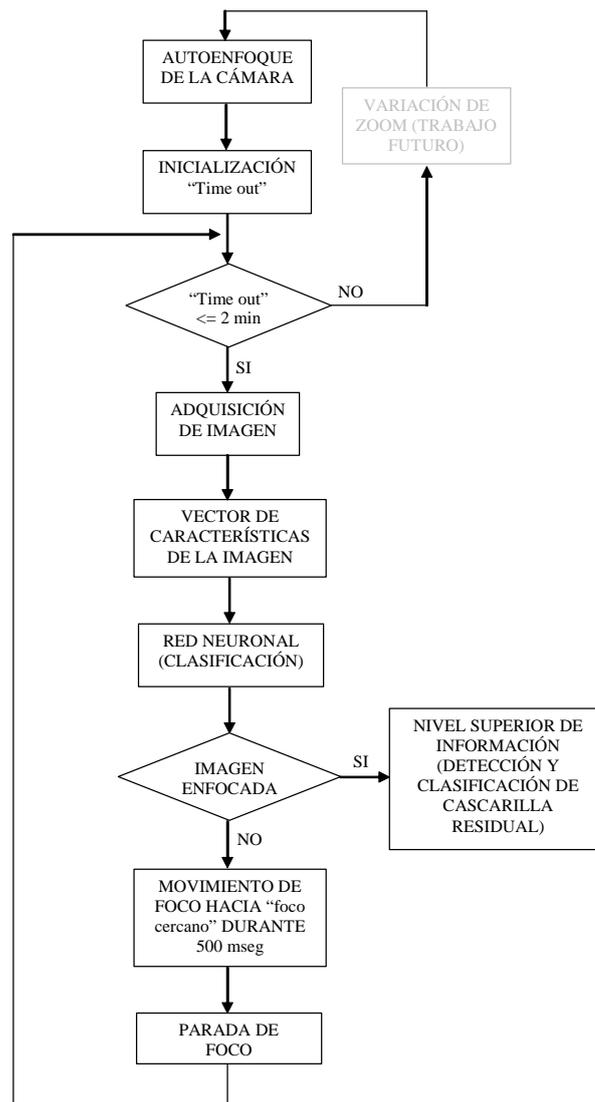
El último paso integra la adquisición de la imagen junto con la clasificación realizada por la red neuronal de dicha imagen en enfocada o desenfocada, para conseguir un sistema automático de enfoque con la cámara Mitsubishi. Como se ha comentado anteriormente, el autoenfoco propio de la cámara es incapaz de enfocar una plancha de acero inoxidable a 30 cm de distancia. El problema de autoenfoco propio de la cámara se soluciona con el sistema de enfoque automático, basado en la red perceptron multicapa que clasifica las imágenes en enfocadas o desenfocadas.

El algoritmo para funcionamiento en tiempo-real del autoenfoco, se basa en la siguiente observación empírica. Primero se utiliza el enfoque automático de la cámara, el resultado es una imagen desenfocada. Segundo, se mueve el foco hacia "foco cercano" o "NEAR" hasta encontrar la imagen enfocada. La imagen enfocada siempre se encuentra hacia "foco cercano" después de aplicar el autoenfoco de la cámara.

El control del algoritmo de autoenfoco se muestra en la figura A.12 y utiliza

el programa de adquisición de imagen anterior y la clasificación de la imagen, con la red MLP, en enfocada o desenfocada. Si la imagen no está enfocada se mueve el foco hacia “foco cercano” hasta encontrarla y si la imagen está enfocada se detecta y clasifica la cascarilla residual de la imagen.

El algoritmo de autoenfoco no busca indefinidamente la imagen enfocada porque se puede dar el caso que la imagen no se pueda enfocar. Por ejemplo, si se aplica un zoom grande la imagen no se puede enfocar ni manual ni automáticamente. El algoritmo posee un “time out” de 2 min para evitar el enfoque indefinido. Es decir, si pasados dos minutos no se ha podido enfocar la imagen, significa que la imagen no se puede enfocar.



**Figura A.12:** Algoritmo de autoenfoco con red neuronal MLP

A continuación, se realizan dos pruebas de autoenfoco en tiempo-real de la plancha de acero inoxidable a inspeccionar. El sistema de autoenfoco consigue enfocar la imagen en menos de dos minutos. Las condiciones de inspección son: distancia de 30 cm entre la cámara y la plancha de acero inoxidable, iluminación con fluorescentes y zoom fijo. La figura A.13 muestra la imagen enfocada automáticamente en el primer experimento. El segundo experimento de autoenfoco se muestra en

la figura A.14. También, se observa en la respuesta de la red neuronal (en ambos experimentos), una vez enfocada la imagen, que la red neuronal la sigue clasificando como imagen enfocada.



**Figura A.13:** Imagen enfocada automáticamente en el experimento 1



**Figura A.14:** Imagen enfocada automáticamente en el experimento 2

#### **A.1.4. Detección de cascarilla en la imagen autoenfocada**

A continuación se muestra la dificultad de detección de cascarilla residual, en este tipo de imagen, en comparación con la detección en imágenes óptimas adquiridas con el sistema de iluminación láser que se vio en el capítulo 4.

Para la detección de cascarilla residual en la imagen autoenfocada de la plancha de acero inoxidable a inspeccionar, se utilizan filtros espaciales que permiten preprocesar la imagen y facilitan la detección. El operador que mejores resultados ha proporcionado es el filtrado pasa alta de la imagen que aumenta el contraste mancha/fondo. Así, al realzar este contraste, una umbralización posterior es suficiente para detectar los defectos de cascarilla.

Otro operador que proporciona buenos resultados es el filtro promedio. La casca-

rilla se aloja en el grano y, por lo tanto, los niveles de gris de ésta no son uniformes. Este filtrado se lleva a cabo para aumentar la uniformidad de las manchas (manteniendo en gran parte el contraste en los bordes).

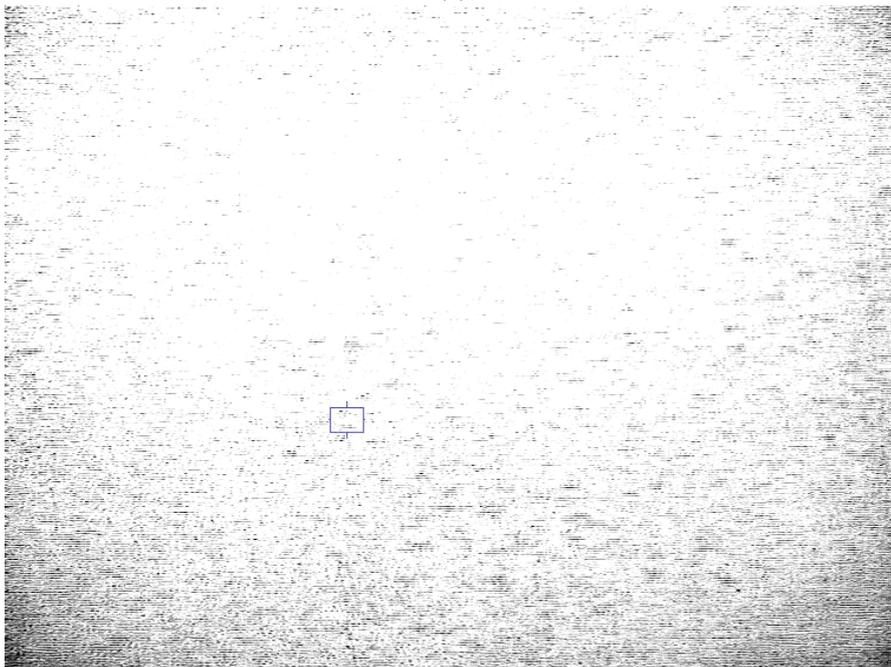
A continuación, se analiza la imagen enfocada automáticamente en el experimento 2 del apartado anterior. Primero, se muestra un pequeño detalle del plano de color rojo sin filtrar en la figura A.15 (a-b). El rango de niveles de gris visualizado es [80-130] ([mínimo nivel de gris del plano rojo - (mínimo+50)]). La detección de cascarilla en esta imagen es difícil.

Primero, se aplica un filtro pasa alta para preprocesar la imagen con el objetivo de facilitar la detección de cascarilla en la imagen. Así, se aplica al plano de color rojo, pero se podría aplicar igualmente al plano de color verde o azul. En esta clase de imagen, el filtro consigue aumentar el contraste mancha/fondo del plano de color rojo. Los resultados se muestran en la figura A.16.

Segundo, se aplica una sencilla binarización para detectar la cascarilla que pueda existir en la imagen. El mínimo nivel de gris de la imagen filtrada es 51 y de forma empírica se ha elegido el umbral: valor mínimo + 30. La siguiente figura A.17 muestra una binarización o umbralización en el nivel de gris 81. En los laterales de la imagen se observa ruido debido a la óptica y al sensor de la cámara (Mitsubishi CCD-300E).

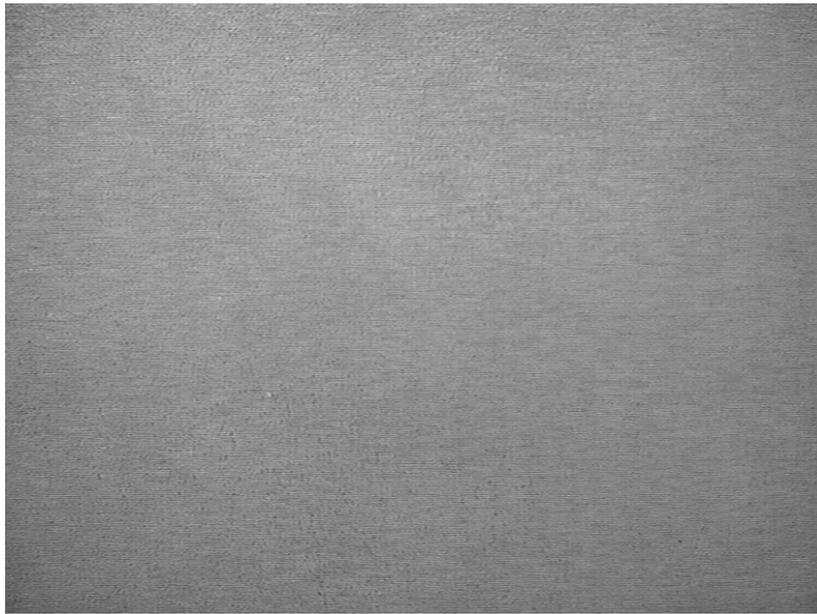
3	153	152	149	150	168	172	173	171	178	173	160	158	166	181	188	177	173	166	170	175	173	167	166	168	159	145	145	150
1	145	140	144	140	135	138	140	127	119	118	140	153	145	126	123	124	126	133	134	135	142	147	145	140	151	150	154	150
3	158	152	154	161	164	158	166	178	177	171	169	163	175	173	172	178	181	167	174	169	164	165	164	156	150	142	142	144
4	136	144	147	142	147	162	146	91	84	98	134	140	115	114	126	128	136	130	131	140	139	140	138	137	143	140	142	138
7	159	163	161	157	148	143	150	156	147	140	169	179	184	165	168	182	180	172	166	132	132	139	141	133	136	150	165	150
3	150	141	137	133	134	125	120	122	126	129	122	113	117	128	128	111	114	125	146	145	140	141	134	132	132	126	126	122
5	147	149	142	142	149	151	155	154	152	160	173	176	184	177	174	144	146	159	143	121	112	123	144	137	130	133	137	140
4	141	148	153	140	140	144	135	140	152	148	129	106	122	141	153	137	135	139	142	151	146	137	139	134	137	163	161	144
2	144	149	141	145	155	151	132	121	139	159	167	157	154	141	141	138	152	158	145	126	127	129	126	128	136	127	127	134
2	133	137	134	142	142	139	141	138	129	122	125	134	150	142	147	148	145	138	144	144	130	127	152	156	156	159	166	170
4	146	145	145	150	149	137	130	131	141	140	142	138	136	145	148	141	149	154	152	147	148	151	162	163	162	151	147	138
3	152	156	152	144	147	140	146	136	129	136	140	151	159	153	141	132	131	138	141	145	162	154	134	123	134	138	145	150
5	147	131	120	131	135	145	145	132	145	151	157	161	150	143	140	138	157	156	160	159	160	159	162	163	153	158	150	133
5	164	159	160	147	148	135	140	140	145	141	141	136	146	148	132	126	135	137	135	134	139	135	132	123	130	136	143	144
3	133	139	137	118	126	152	171	162	151	153	160	164	159	156	157	159	161	162	159	167	169	150	150	163	164	147	144	140
3	154	139	137	139	141	137	121	124	123	110	108	117	130	136	120	114	106	117	138	144	137	137	138	129	130	138	138	144
3	144	151	161	165	163	159	159	162	172	178	178	174	175	180	180	160	151	162	182	176	164	163	175	182	165	147	156	140
7	127	123	126	136	138	142	135	127	126	120	118	116	117	113	119	110	103	107	123	113	116	125	128	130	132	132	135	138
3	152	164	168	160	151	159	170	162	153	156	164	166	161	165	160	157	161	165	176	174	169	168	162	151	148	149	146	133
7	146	138	124	127	142	142	128	122	112	134	156	153	128	130	140	150	150	131	137	142	126	127	132	137	139	138	140	140
2	153	148	154	151	160	160	153	132	122	123	140	152	158	141	138	137	154	160	157	159	170	159	141	132	143	155	158	150
5	122	110	116	123	128	123	116	102	110	126	155	152	140	136	140	140	142	135	137	141	148	136	118	111	123	138	135	130

(a)



(b)

**Figura A.15:** (a) Detalle del plano de color rojo, (b) Localización del detalle de la figura (a) en el plano rojo. En (a) y (b), se visualiza solo el rango de niveles de gris [80 130]



**Figura A.16:** Plano de color rojo después de aplicar el filtro pasa alta



**Figura A.17:** Umbralización de valor 81, en el plano de color rojo filtrado pasa alta

También, se realiza un análisis detallado de la umbralización anterior, utilizando la imagen filtrada en el rango de niveles de gris [50 100]. La figura A.18 (a-b) analiza

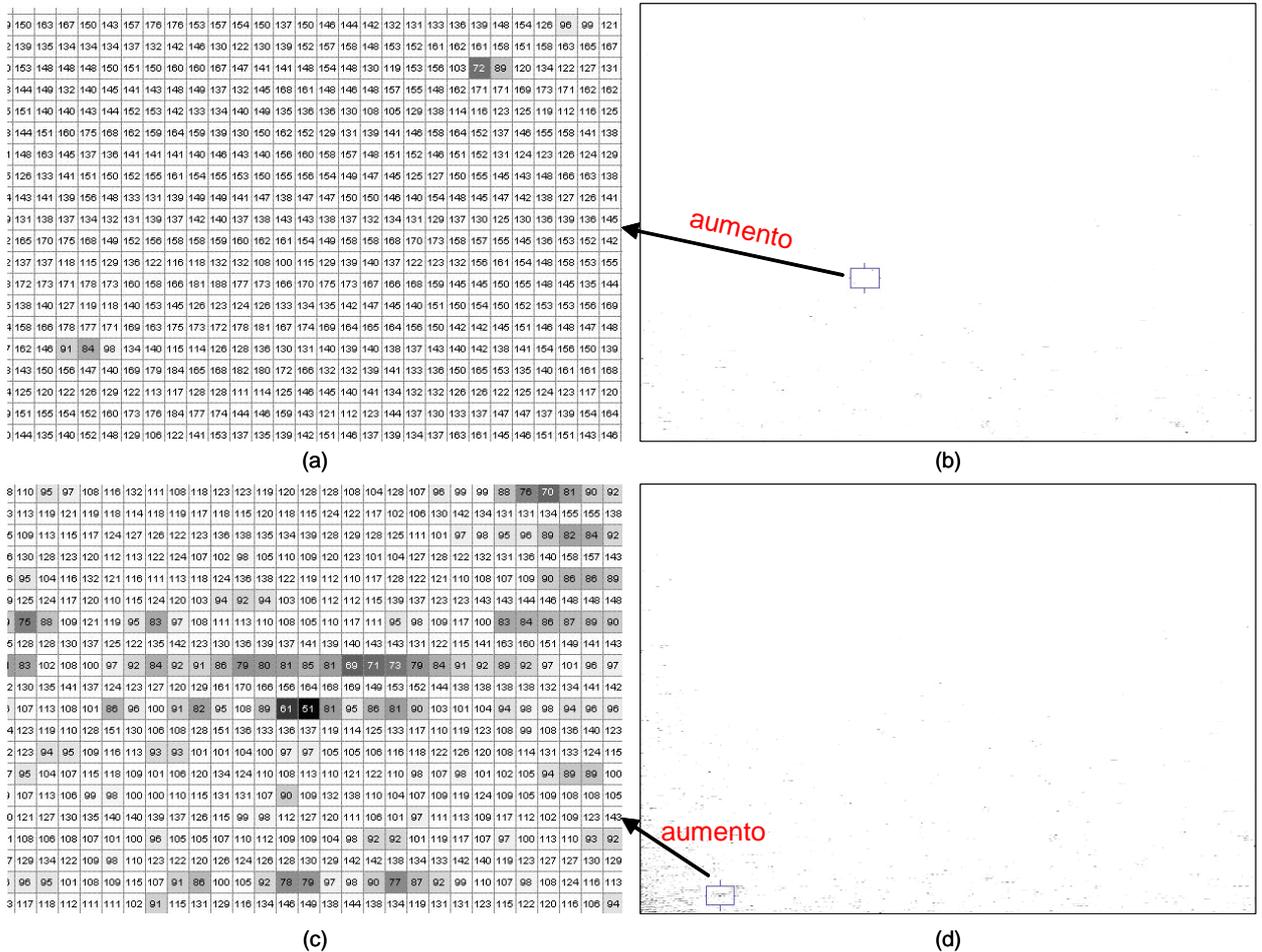
un pequeño defecto de cascarilla y la figura A.18 (c-d) analiza el ruido de una de las esquinas donde se localiza el menor nivel de gris. Como se puede observar en las imágenes, la cascarilla no posee el menor nivel de gris. Ésta se encuentra en un rango de niveles de gris [70 90]. También se observa que los niveles de gris que rodean las manchas de cascarilla son mayores (acero inoxidable).

Finalmente, se demuestra la diferencia que existe entre el plano de color rojo y el plano de color rojo filtrado pasa alta. Esta demostración se realiza porque a simple vista no se aprecian diferencias entre las dos imágenes.

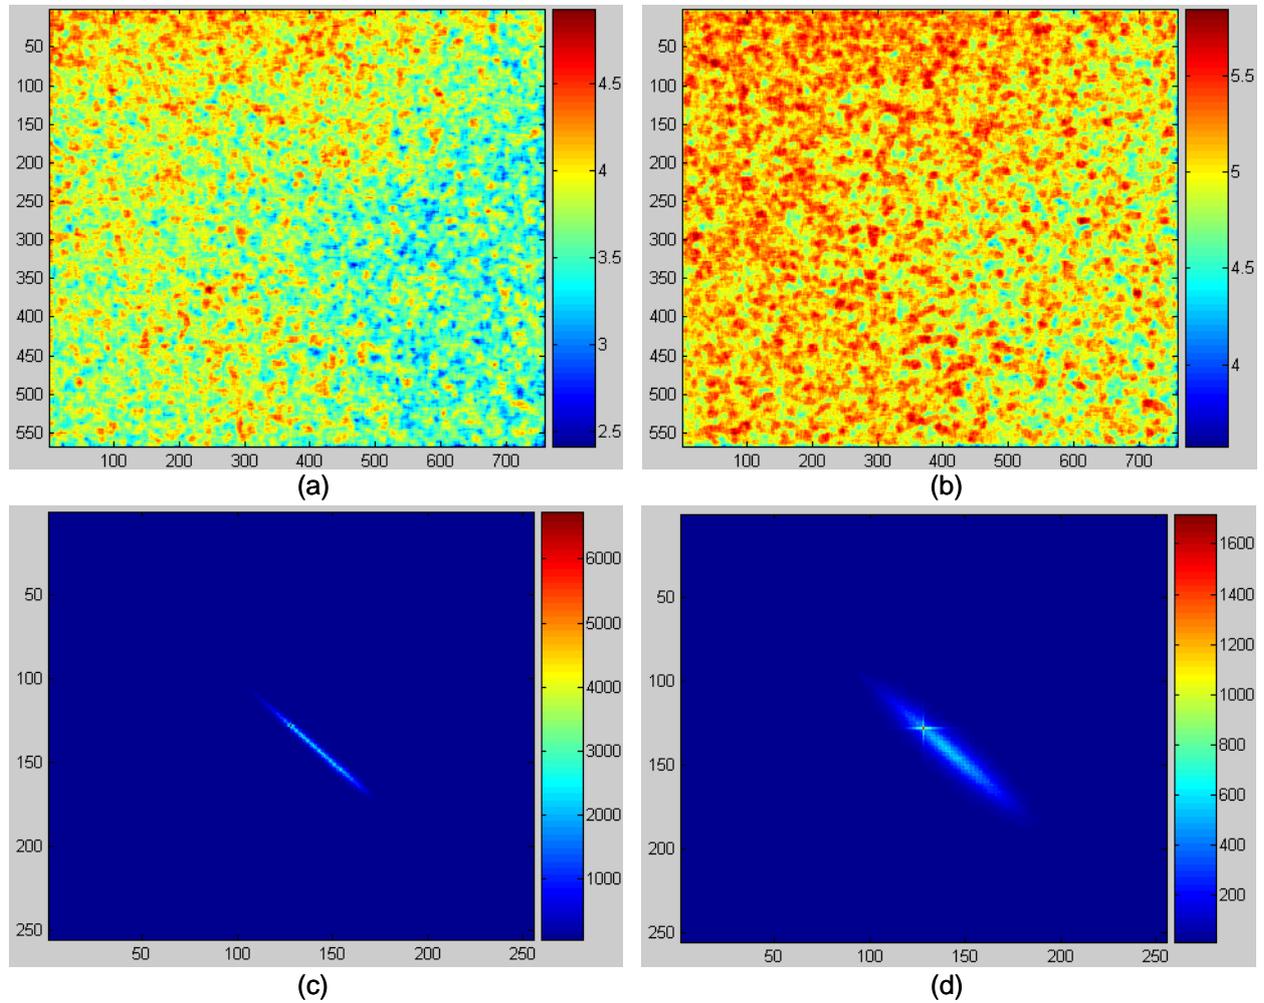
Las diferencias se muestran mediante dos métodos:

- Entropía local. En dicho método se calcula la entropía de una vecindad  $9 \times 9$  alrededor de cada píxel de la imagen original (plano de color rojo y plano de color rojo filtrado pasa alta). El valor de cada píxel en la nueva imagen es el de cada entropía local. En la figura A.19a se puede observar la entropía local del plano de color rojo y en la figura A.19b la entropía local del plano de color rojo filtrado. Así pues, se observa que la entropía local en el plano de color rojo filtrado pasa alta es mayor que la entropía en el plano de color rojo.
- Matriz de co-ocurrencia. Los resultados se muestran en la figura A.19c (plano de color rojo) y figura A.19d (plano de color rojo filtrado pasa alta). Las estadísticas de cada matriz de co-ocurrencia son las siguientes, donde las mayores diferencias entre las dos matrices de co-ocurrencia se observan en el contraste y la energía:

```
PlanoRojoGLCMestadistica =  
Contrast: 5.4346  
Correlation: 0.9867  
Energy: 0.0028  
Homogeneity: 0.5156  
PlanoRojoFiltroUnsharpGLCMestadistica =  
Contrast: 67.5289  
Correlation: 0.9084  
Energy: 6.0486e-004  
Homogeneity: 0.2593
```



**Figura A.18:** (a) Detalle de cascarilla en la imagen filtrada pasa alta, (b) Localización del detalle de cascarilla de la figura (a) en la imagen filtrada, (c) Detalle de ruido en la imagen filtrada pasa alta, (d) Localización del detalle de ruido de la figura (c) en la imagen filtrada. En las cuatro figuras solo se sombrea el rango de niveles de gris [50 100]



**Figura A.19:** (a) Entropía local del plano de color rojo, (b) Entropía local del plano de color rojo filtrado pasa alta, (c) Matriz de co-ocurrencia del plano de color rojo, (d) Matriz de co-ocurrencia del plano de color rojo filtrado pasa alta

## **A.2. Segmentación y clasificación de cascarilla residual mediante redes SOFM**

Este apartado muestra un enfoque no supervisado para segmentar defectos de cascarilla residual y clasificar las distintas regiones de una imagen con cascarilla. Así, se distingue entre defectos de cascarilla, sombras producidas por iluminación no uniforme u otro tipo de defecto y acero base. Pero en este caso, al tratarse de aprendizaje no supervisado, a priori no se conoce con exactitud este tipo de información.

La red utilizada se denomina SOFM (Self Organization Feature Map) y se va a encargar de agrupar, extraer las clases de objetos y clasificar las regiones que componen la imagen.

La información de las imágenes de acero es difícil de extraer. Por ejemplo, la umbralización de la imagen, en algunos casos, no aporta buenos resultados debido a que los niveles de gris están muy juntos y no se aprecia ningún lóbulo que diferencie entre acero, cascarilla, sombras y otros tipos de defectos. Por lo tanto, en este apéndice, se muestra el caso de agrupación, segmentación y clasificación mediante redes SOFM, que se basan en aprendizaje no supervisado.

Las redes SOFM pertenecen al grupo de las redes competitivas o mapas autoorganizados y se fundamentan en el aprendizaje no supervisado de tipo competitivo. Poseen una arquitectura de dos capas (entrada-salida) y flujo de información unidireccional. Éstas aprenden a clasificar vectores de entrada de acuerdo a como se agrupan en el espacio de entrada. Es decir, aprenden la distribución y la topología de los vectores de entrada que se utilizan para entrenar la red. Las neuronas se organizan en la capa de salida en posiciones físicas, en función del tipo de topología. Las topologías pueden ser cuadrícula, hexagonal o aleatoria. Las distancias entre neuronas se pueden calcular con las siguientes funciones distancia: distancia de caja (“boxdistance”), distancia euclídea, distancia de eslabón (“linkdistance”) y

distancia de Manhattan. Así, tras el aprendizaje de la red, cada vector de entrada activa una única unidad de salida. El objetivo de la red es clasificar los vectores de entrada en grupos de características similares, de forma que cada grupo activara siempre las mismas neuronas de salida. Cada grupo de entrada queda representado en los pesos de las conexiones de la neurona de salida ganadora. Así, después de entrenar la red se conocerá la neurona ganadora para cada grupo de entrada. Una vez entrenada la red se puede usar para clasificar vectores de entrada diferentes a los de entrenamiento. Una clase o grupo de vectores de entrada tiende a controlar una neurona específica, es decir, esta neurona resultará más activada con los vectores de entrada más parecidos a su vector de pesos.

La clasificación consiste en presentar un vector de características (capa de entrada) y seleccionar la neurona más activada (capa de salida) mediante la función de distancia utilizada.

El problema se va a implementar en Matlab, utilizando la Toolbox Neural Network. Esta herramienta permite construir la red y variar los parámetros de la red neuronal SOFM para estudiar cual es la red que mejor se ajusta a la solución del problema. Por ejemplo, elegir el tipo de topología, el tipo de función distancia, número de veces que se presentan a la red el conjunto de vectores de entrenamiento (épocas) en la fase de entrenamiento, etc.

### **A.2.1. Problema a solucionar y método para solucionarlo**

El problema a solucionar es la detección y clasificación de defectos de cascarilla (pequeñas manchas de oxido de entre 20 y 100  $\mu m$ ) en imágenes de planchas de acero inoxidable.

El objetivo de las redes neuronales artificiales SOFM es agrupar la clase “manchas de cascarilla” en imágenes donde no es tan evidente la existencia de manchas, para su posterior uso en clasificación. La clasificación se puede realizar mediante la propia red SOFM u otros métodos de aprendizaje supervisado (MLP o RBF) debido

a que ya conocemos los vectores de entrada y las clases correspondientes a las que pertenecen.

La red se entrena con imágenes donde claramente se aprecia cascarilla con el objetivo de detectar manchas en otras imágenes, donde no sea evidente la existencia de cascarilla.

Primero se construye la red con los requisitos que se desean (dimensión del vector de características, rango de valores que puede tomar cada componente del vector de características, n° de neuronas en la capa de salida, tipo de topología, tasa de aprendizaje, función distancia, etc.). Segundo se inicializan los pesos de la red; en este caso, se selecciona el punto medio del rango de valores que puede tomar cada componente del vector de características. Tercero se entrena la red con el conjunto de entrenamiento (mitad de una imagen; definiendo los distintos parámetros de entrenamiento, por ejemplo, el número de veces que queremos pasar todo el conjunto de entrenamiento para entrenar la red). Estos tres pasos producen un mapa de neuronas organizado, es decir, las distintas clases que hay en la imagen de entrenamiento “clustering”. Finalmente, una vez localizadas las distintas clases se utiliza un conjunto de prueba, que es el resto de la imagen, para clasificar los nuevos píxeles que no sabemos a que clase pertenecen. Es decir, clasificar si son cascarilla, acero, ruido, etc.

La solución del problema está orientada hacia dos métodos. Estos relativos al tipo de vector de características que se utiliza en la red SOFM. El primero extrae características de cada píxel de la imagen. En cada píxel de la imagen se realizan 12 operaciones (filtrado, morfológicas, etc) utilizando una vecindad  $3 \times 3$ . Así, de cada píxel obtenemos 12 características que forman la capa de entrada (en los experimentos se muestra que una de las propiedades de las redes SOFM es la reducción de la dimensionalidad de la capa de entrada).

El segundo método utiliza directamente la imagen, es decir, divide la imagen en ventanas  $2 \times 1$  y cada una pasa a ser un vector de características de 2 dimensiones.

Resumiendo:

- a) SOFM con características: entrada, [2 – 12] características; salida, 4 neuronas.
- b) SOFM con imagen directa: entrada [n×m] píxeles; salida, 4 neuronas.

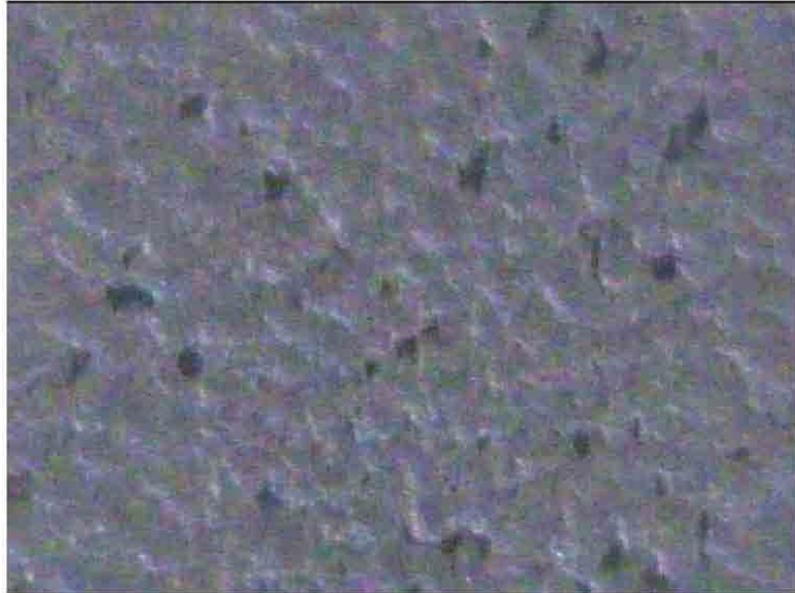
### **A.2.2. Descripción del problema y recursos para la solución del problema (imágenes y vectores de características)**

La información para solucionar el problema está en las imágenes de planchas de acero tomadas en laboratorio. La facilidad de adquisición permite disponer de una gran cantidad de imágenes con defectos de manchas de cascarilla residual. En este caso se utilizan planchas “tipo C”, en las cuales se puede observar cascarilla a simple vista debido a que el tamaño de mancha puede llegar a ser de 250  $\mu m$  aproximadamente. El sistema basado en redes neuronales artificiales es capaz de extraer las regularidades y correlaciones de la imagen (manchas de cascarilla, sombras y otros tipos de defectos) y descubrir las distintas clases que forman la imagen (“clustering”)

Las imágenes que componen el conjunto de entrenamiento y prueba son un grupo de 20 imágenes color; 24 bits-RGB con resolución 220×300. Cada imagen está compuesta por tres planos de color de 8 bits; plano de color rojo, plano de color verde y plano de color azul. Cada plano de color es una imagen de intensidades y cada píxel está representado por un valor entre 0 y 255; es decir, es una imagen en escala de grises, el 0 representa el negro y el 255 el blanco. La figura A.20 muestra una imagen original en color.

A continuación se detallan cada una de las características que forman el vector de características para entrenamiento y prueba de la red SOFM. Por cada plano de color tendremos 66000 vectores de características (formados por 12 características cada uno) y debido a que cada imagen RGB tiene tres planos de color, obtendremos un conjunto de entrenamiento y prueba de 66000 vectores de características del plano de color rojo + 66000 vectores de características del plano de color verde +

66000 vectores de características del plano de color azul. En total 198000 vectores de características para entrenamiento y prueba. Todo el conjunto de vectores de características se ha obtenido mediante Matlab y todas las imágenes preprocesadas son de resolución  $220 \times 300$  como los planos de color originales.



**Figura A.20:** Imagen original con defectos de cascarilla residual

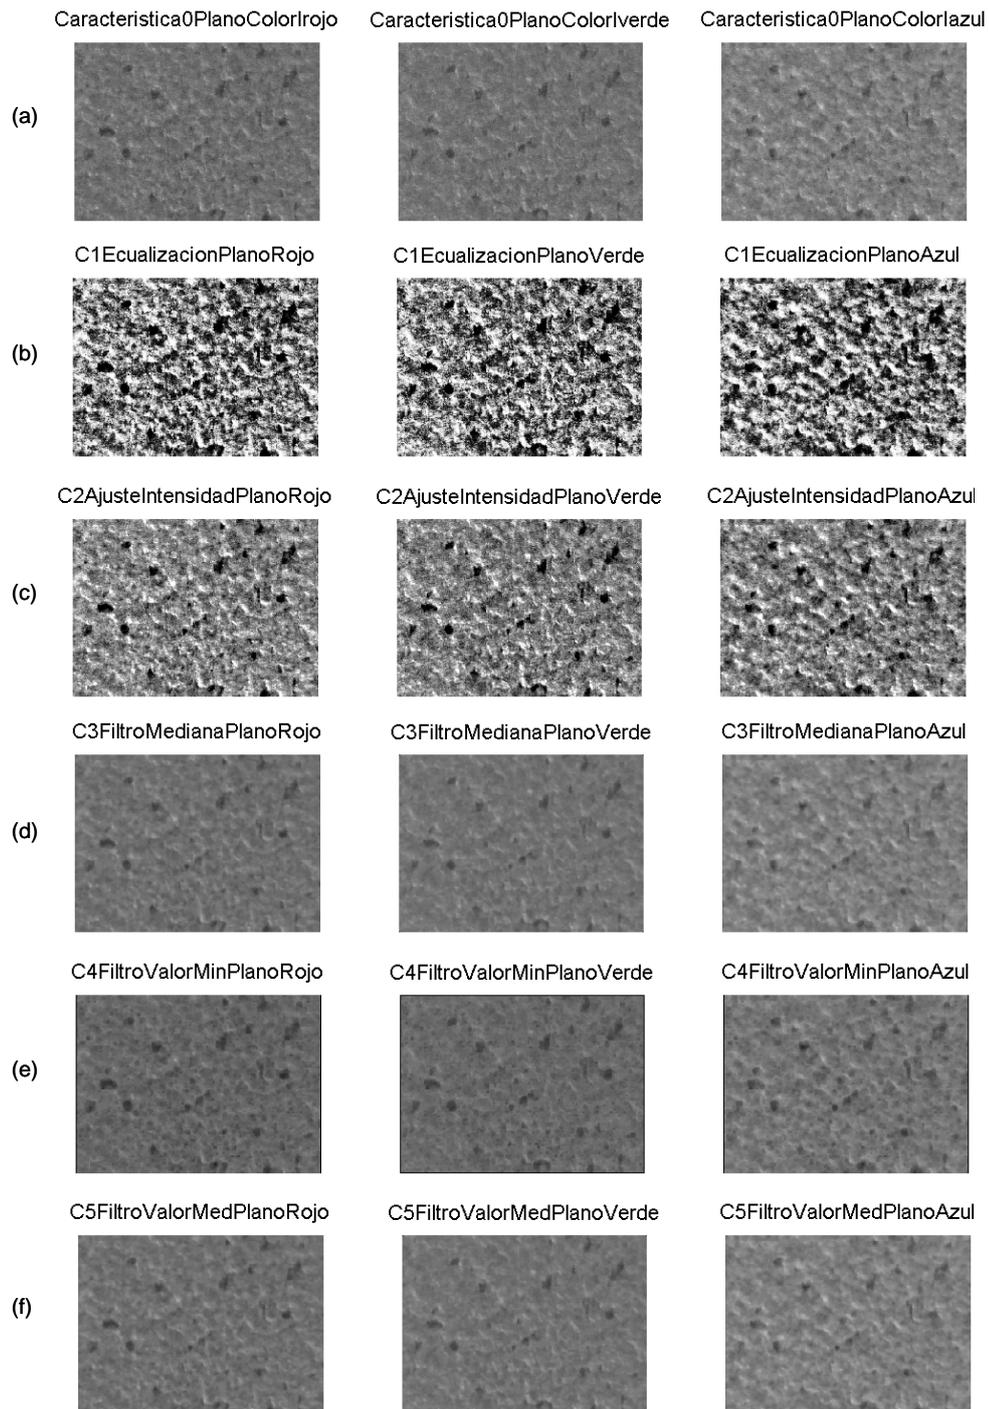
- Característica 0 (fig. A.21a); Plano de color original.
- Característica 1 (fig. A.21b); Ecuilización del histograma: realza el contraste de los planos de color.
- Característica 2 (fig. A.21c); Ajuste de intensidad: consiste en localizar el nivel mínimo y máximo de gris en un plano de color y ajustarlos a sus extremos  $[0 \ 255]$ , para extender el contraste del plano de color.
- Característica 3 (fig. A.21d); Filtro de valor medio usando vecindad  $3 \times 3$ : es una operación no lineal que a menudo se suele utilizar para reducir el ruido denominado “sal y pimienta”.
- Característica 4 (fig. A.21e); Filtro valor mínimo usando vecindad  $3 \times 3$ : cada píxel obtenido con este método de filtrado, contiene el valor mínimo de intensidad de una vecindad  $3 \times 3$  alrededor del píxel correspondiente en el plano de color original.
- Característica 5 (fig. A.21f); Filtro valor mediano usando vecindad  $3 \times 3$ : cada píxel obtenido con este método de filtrado, contiene el valor mediano de intensidad de una vecindad  $3 \times 3$  alrededor del píxel correspondiente en el plano de color original.

- Característica 6 (fig. A.22a); Filtro valor máximo usando vecindad  $3 \times 3$ : cada píxel obtenido con este método de filtrado, contiene el valor máximo de intensidad de una vecindad  $3 \times 3$  alrededor del píxel correspondiente en el plano de color original.
- Característica 7 (fig. A.22b); Filtro utilizando el método de Wiener y usando vecindad  $3 \times 3$ .
- Característica 8 (fig. A.22c); Operación morfológica de cierre usando vecindad  $3 \times 3$ .
- Característica 9 (fig. A.22d); Operación morfológica de apertura usando vecindad  $3 \times 3$ .
- Característica 10 (fig. A.22e); Operación morfológica de dilatación usando vecindad  $3 \times 3$ .
- Característica 11 (fig. A.22f); Operación morfológica de erosión usando vecindad  $3 \times 3$ .

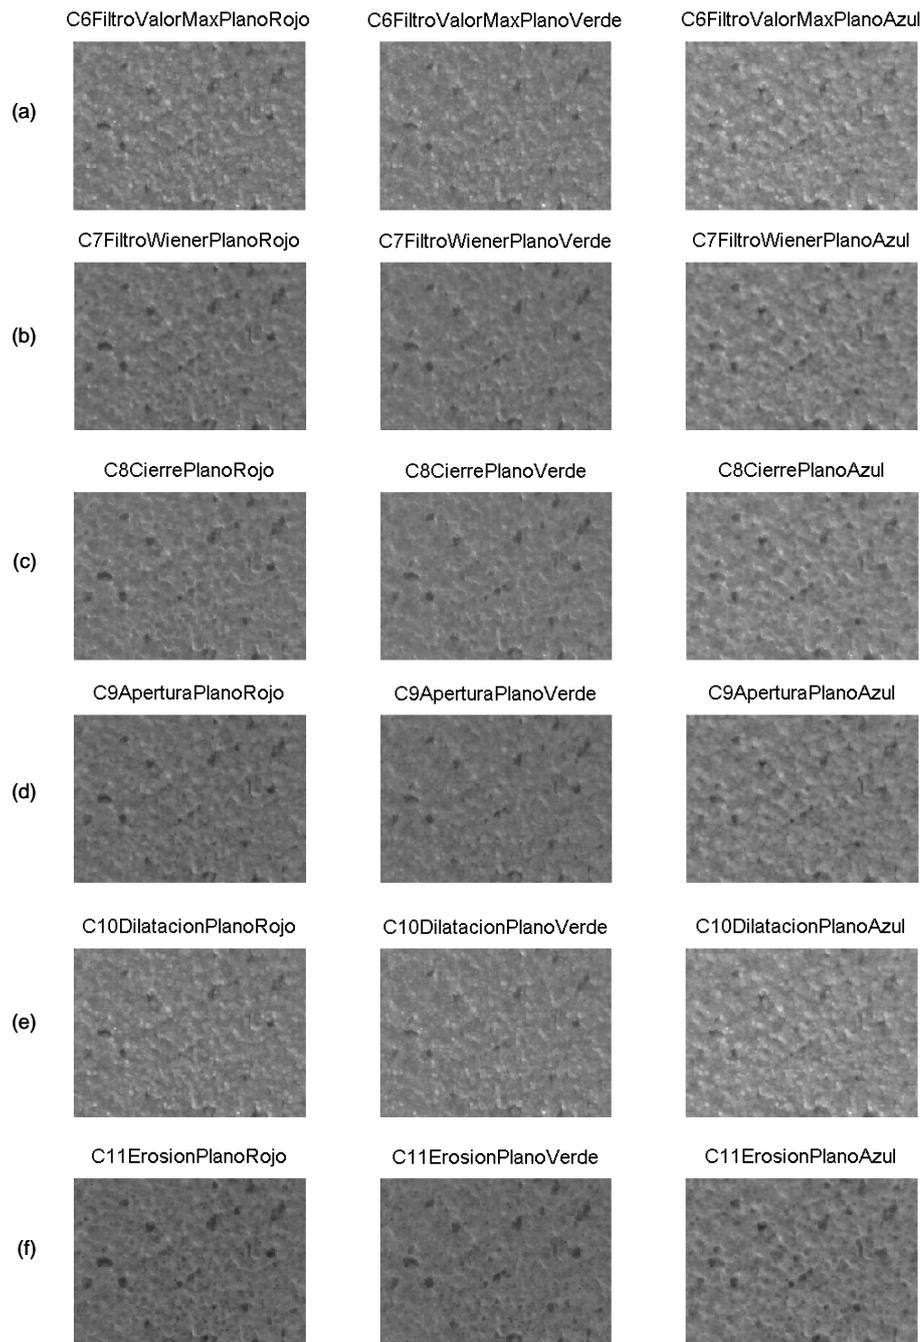
### **A.2.3. Formas de evaluar la calidad de la solución**

La evaluación de la solución se realiza de dos formas. La primera compara los resultados de clasificación obtenidos por la red en la etapa de prueba, con la clasificación realizada por expertos (control de calidad; acero tipo A, B, C y D). La segunda relativa a la eficiencia de la red (tiempo de cálculo, tipo de función utilizada para calcular la distancia entre las neuronas, topología, etc.).

Las planchas de acero inoxidable tienen 4 niveles de calidad: calidad A (sin cascarilla), calidad B (muy poca cascarilla, no se aprecia a simple vista ( $\sim 50 \mu m$ )), calidad C (poca cascarilla, se aprecia a simple vista), calidad D (mucho cascarilla). Todas las planchas del laboratorio están etiquetadas en función de estas cuatro clases. Debido a que existe una gran variedad de planchas se ha decidido utilizar en este caso, planchas tipo C, por facilidad de localización de las manchas a simple vista. Este tipo de plancha permite evaluar si la red localiza un “grupo de defectos de cascarilla” sabiendo a priori que existe cascarilla en la imagen. Como se comentó anteriormente uno de los objetivos de la red SOFM es encontrar los distintos “grupos de defectos” que existen en la imagen. Una vez localizados los distintos grupos



**Figura A.21:** (a) Característica 0; Plano de color original, (b) Característica 1; Ecuación del histograma, (c) Característica 2; Ajuste de intensidad, (d) Característica 3; Filtro de valor medio usando vecindad  $3 \times 3$ , (e) Característica 4; Filtro valor mínimo usando vecindad  $3 \times 3$ , (f) Característica 5; Filtro valor mediano usando vecindad  $3 \times 3$



**Figura A.22:** (a) C6; Filtro valor máximo usando vecindad  $3 \times 3$ , (b) C7; Filtro utilizando el método de Wiener y usando vecindad  $3 \times 3$ , (c) C8; Operación morfológica de cierre usando vecindad  $3 \times 3$ , (d) C9; Operación morfológica de apertura usando vecindad  $3 \times 3$ , (e) C10; Operación morfológica de dilatación usando vecindad  $3 \times 3$ , (f) C11; Operación morfológica de erosión usando vecindad  $3 \times 3$

(“clusters”) por la red SOFM entrenada, se podría clasificar cualquier imagen de acero inoxidable en los distintos grupos encontrados.

La eficiencia de la red desde el punto de vista del tiempo de cálculo es óptima. Esto se debe a que los tiempos de entrenamiento de una red SOFM con 12 entradas, 4 salidas, un conjunto de entrenamiento de 33000 vectores y 1 época (pasa sólo 1 vez todo en conjunto de entrenamiento), son aproximadamente 1 min. en un PC con procesador Pentium IV y sistema operativo Windows XP. Otras formas de evaluar la eficiencia son los resultados de la red SOFM, utilizando distintas funciones para calcular la distancia entre las neuronas. En el siguiente apartado se muestra el entrenamiento con distintas funciones distancia para observar el comportamiento de la red SOFM, sin variar la topología (sólo se ha entrenado las redes SOFM con topología hexagonal).

#### **A.2.4. Subtareas del problema. Solución mediante SOFM**

Las tres subtareas del trabajo son: agrupación, segmentación y clasificación de la imagen. Las tres subtareas se resuelven utilizando redes SOFM.

La subtarea de agrupación se consigue con el entrenamiento de la red; como se comentó anteriormente en la descripción del problema global, existe muy poca información de las distintas clases que forman el espacio de entrada. Esta primera subtarea busca las distintas clases que existen en la imagen de entrenamiento.

La segunda subtarea clasifica a partir de la red SOFM entrenada, los nuevos píxeles de las imágenes de prueba.

La segunda subtarea soluciona también la tercera, ya que la segmentación es el proceso que extrae información de una imagen para su uso posterior. En este caso sería segmentación orientada a regiones. Una región es un área de la imagen en la que sus píxeles poseen propiedades iguales (intensidad, color, etc.); en este caso, son áreas en las cuales sus píxeles poseen la propiedad de pertenecer a una determinada

TIPO DE TAREA	AUTORES
Redes neuronales en el campo de la imagen medica	[Christoyianni et al., 2002], [Chai et al., 2001], [Hsu & Tseng, 2001], [Rajab et al., 2004], [Riviere et al., 2002]
Reconocimiento de objetos e interpretación de imágenes mediante redes neuronales	[Carpenter et al., 1998], [Chiang & Gader, 1997]
Preprocesado de imagen	[Kouzani, 2003], [Pasquariello et al., 1998]
Clasificación	[Haering & da Victoria Lobo, 1999], [Giacinto & Roli, 2001], [Kobashi et al., 2001], [Sams & Hansen, 2000], [Frosyniotis et al., 2003], [Egmont-Petersen & Pelikan, 1999], [Venkatesh & Kumar Raja, 2003], [Cabello et al., 2002], [Stojanovic et al., 2001], [Tan et al., 1999]
Comparación con otros clasificadores	[Frangi et al., 2001], [Tolba & Abu-Rezq, 2000], [Grim et al., 2002]
Revisión general de trabajos en visión artificial	[Rosenfeld, 2000b]
Mapas Autoorganizados. Red neuronal de Kohonen	[Roh et al., 2003], [Takatsuka & Jarvis, 2001], [Papamarkos et al., 2000], [Villmann et al., 2003]
Funciones de base radial (RBF networks)	[Howell & Buxton, 2002], [Bischof & Leonardis, 2001], [Ng & Ranganath, 2002], [Casasent & Chen, 2003]
Redes neuronales de Hopfield	[Campadelli et al., 1997], [Suganthan et al., 1997], [Chang & Chung, 2001], [Achour & Mahiddine, 2002], [Huang & Huang, 1998], [Convertino et al., 1997], [Ruichek & Postaire, 1999]
Redes neuronales aplicadas a imágenes en movimiento	[Wohler & Anlauf, 1999], [Xu & Hogg, 1997], [Babu & Ramakrishnan, 2004], [Wohler & Anlauf, 2001]
Agrupamiento (“clustering”)	[Agarwal & Chaudhuri, 1998]

**Tabla A.2:** Recopilación de varios artículos sobre redes SOFM en visión artificial

clase.

Las redes SOFM han sido utilizadas en diferentes trabajos de visión artificial. En concreto, no se encuentran en la bibliografía trabajos relativos a “clustering” o agrupamiento en imágenes de planchas de acero inoxidable, pero sí en otros campos como la imagen medica o las imágenes de ultrasonidos. La bibliografía consultada sobre redes SOFM en visión artificial aporta información de los dos métodos planteados para resolver las tareas (tabla A.2).

El primer método se basa en la extracción de características de una imagen píxel

a píxel, es decir, se aplican varias operaciones de vecindad entorno a un píxel y cada resultado forma una característica. Finalmente, todas las características juntas de cada píxel forman un vector de entrenamiento o prueba de la red [Chai et al., 2001].

El segundo método consiste en utilizar directamente la imagen a inspeccionar y subdividirla en pequeñas ventanas que pasan a formar los vectores de entrenamiento y prueba de la red. Este método lo utiliza [Pasquariello et al., 1998] en un artículo sobre detección de barcos en un puerto a partir de imágenes generadas por un RADAR; utiliza una red SOFM con 9 entradas debido a que va cogiendo ventanas  $3 \times 3$  de la imagen, 4 nodos de salida y un conjunto de entrenamiento de 63460 ventanas  $3 \times 3$ .

Por lo tanto, se han utilizado los dos métodos en la experimentación a partir de imágenes de defectos de cascarilla con el objetivo de comparar los resultados y deducir cual soluciona mejor el problema.

Las imágenes de la planchas de acero inoxidable son de tipo RGB. Para el entrenamiento y prueba de las redes SOFM se han utilizado los planos de color que forman la imagen RGB. Así, cada plano de color aporta distintos vectores de características al método 1 y distintas ventanas al método 2.

La información contenida en una imagen RGB es muy grande, por lo tanto, se utiliza sólo un plano de color y no los tres para estudiar las distintas propiedades y resultados de una red.

#### **A.2.4.1. Método 1. Vectores de características**

El método basado en vector de características utiliza 12 características de cada píxel. Pero, debido a que no se puede visualizar gráficamente un espacio de 12 dimensiones, se utilizan 2 dimensiones para observar gráficamente el entrenamiento de las redes. Por otro lado, para observar mejor las propiedades de cada característica se emparejan todas con la primera. Es decir, la primera red SOFM tiene un vector de dos características C1 y C2, la segunda red SOFM C1 y C3, la tercera C1 y C4,

etc.

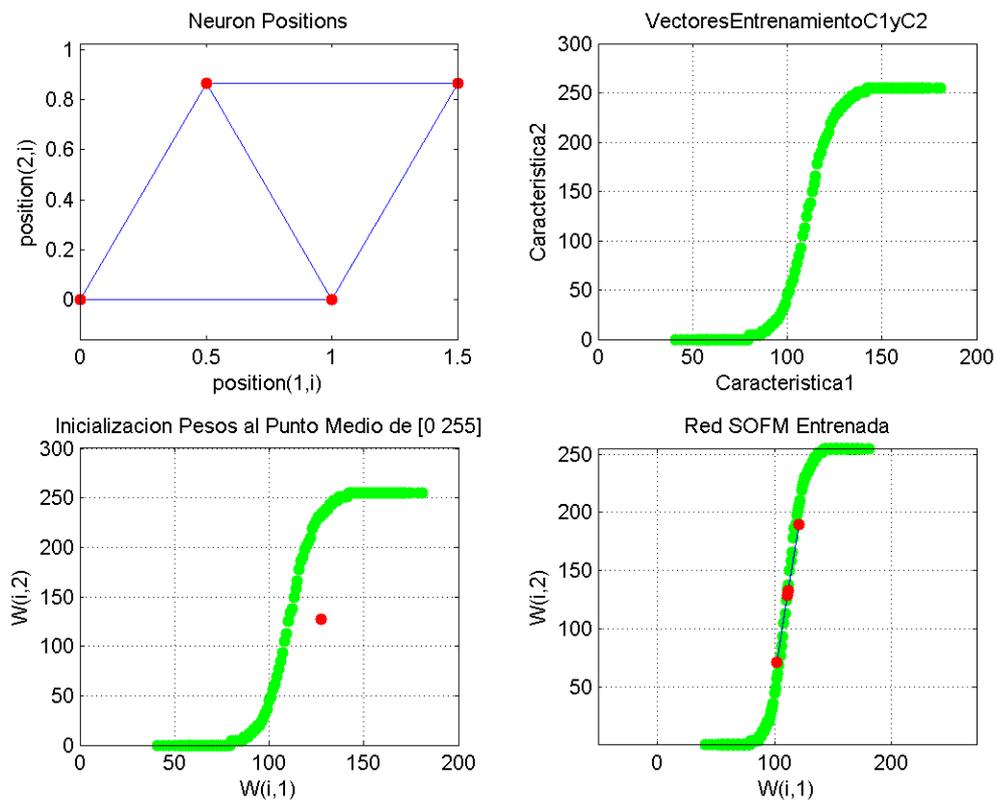
La figura A.23 muestra un ejemplo de entrenamiento de red SOFM con las siguientes propiedades:

- Conjunto de entrenamiento: mitad del plano de color rojo (la otra mitad se destina a prueba de la red) de la primera imagen RGB => 33000 píxeles × 2 características.
- 2 entradas.
- 4 neuronas de salida.
- Topología hexagonal.
- Función “Link Distance” usada para calcular la distancia entre neuronas.
- Tasa de aprendizaje en la fase inicial, por defecto = 0,9.
- Pasos en la fase inicial, por defecto = 1000.
- Tasa de aprendizaje en la fase de ajuste, por defecto = 0,02.
- Distancia de vecindad en la fase de ajuste, por defecto = 1.
- 1 época de entrenamiento (sólo se pasa una vez el conjunto de entrenamiento).

La red está entrenada con 4 neuronas de salida, pero sólo aparecen 3 clases. El plano de color rojo está compuesto por tres clases, ya que dos neuronas aparecen juntas como si de una única clase se tratara. Podríamos asignar a cada clase las siguientes regiones (segmentación por regiones): la clase más cercana al origen podría ser relativa a cascarilla, la clase central a sombras o ruido de la imagen y la clase más alejada del origen a acero inoxidable (región de mayor reflexión y, por lo tanto, de mayores niveles de gris). Pero realmente, las clases están demasiado juntas y no representan bien las distintas regiones (es difícil segmentar la imagen). Por ejemplo, la clase perteneciente a cascarilla está demasiado alejada de los niveles de gris que la caracterizan (35 - 45).

También se observa demasiado ruido al introducir muchos datos (33000×12).

El mapa autoorganizado (capa de salida) que presenta una clase más cercana a la zona de cascarilla es el correspondiente a la red entrenada con el vector de características C1 y C2 (figura A.23).



**Figura A.23:** SOFM entrenada con Característica 1 y Característica 2

A continuación se reduce el conjunto de entrenamiento de la red SOFM y se mantienen todas las propiedades anteriores, excepto la función distancia que en este caso se utiliza “Box Distance”. El nuevo conjunto de entrenamiento es una pequeña parte del plano de color rojo de la primera imagen RGB  $\Rightarrow$  2000 píxeles  $\times$  2 características.

La reducción de datos permite observar la existencia de una clase cerca del origen que debe de pertenecer a los defectos de cascarilla en la imagen.

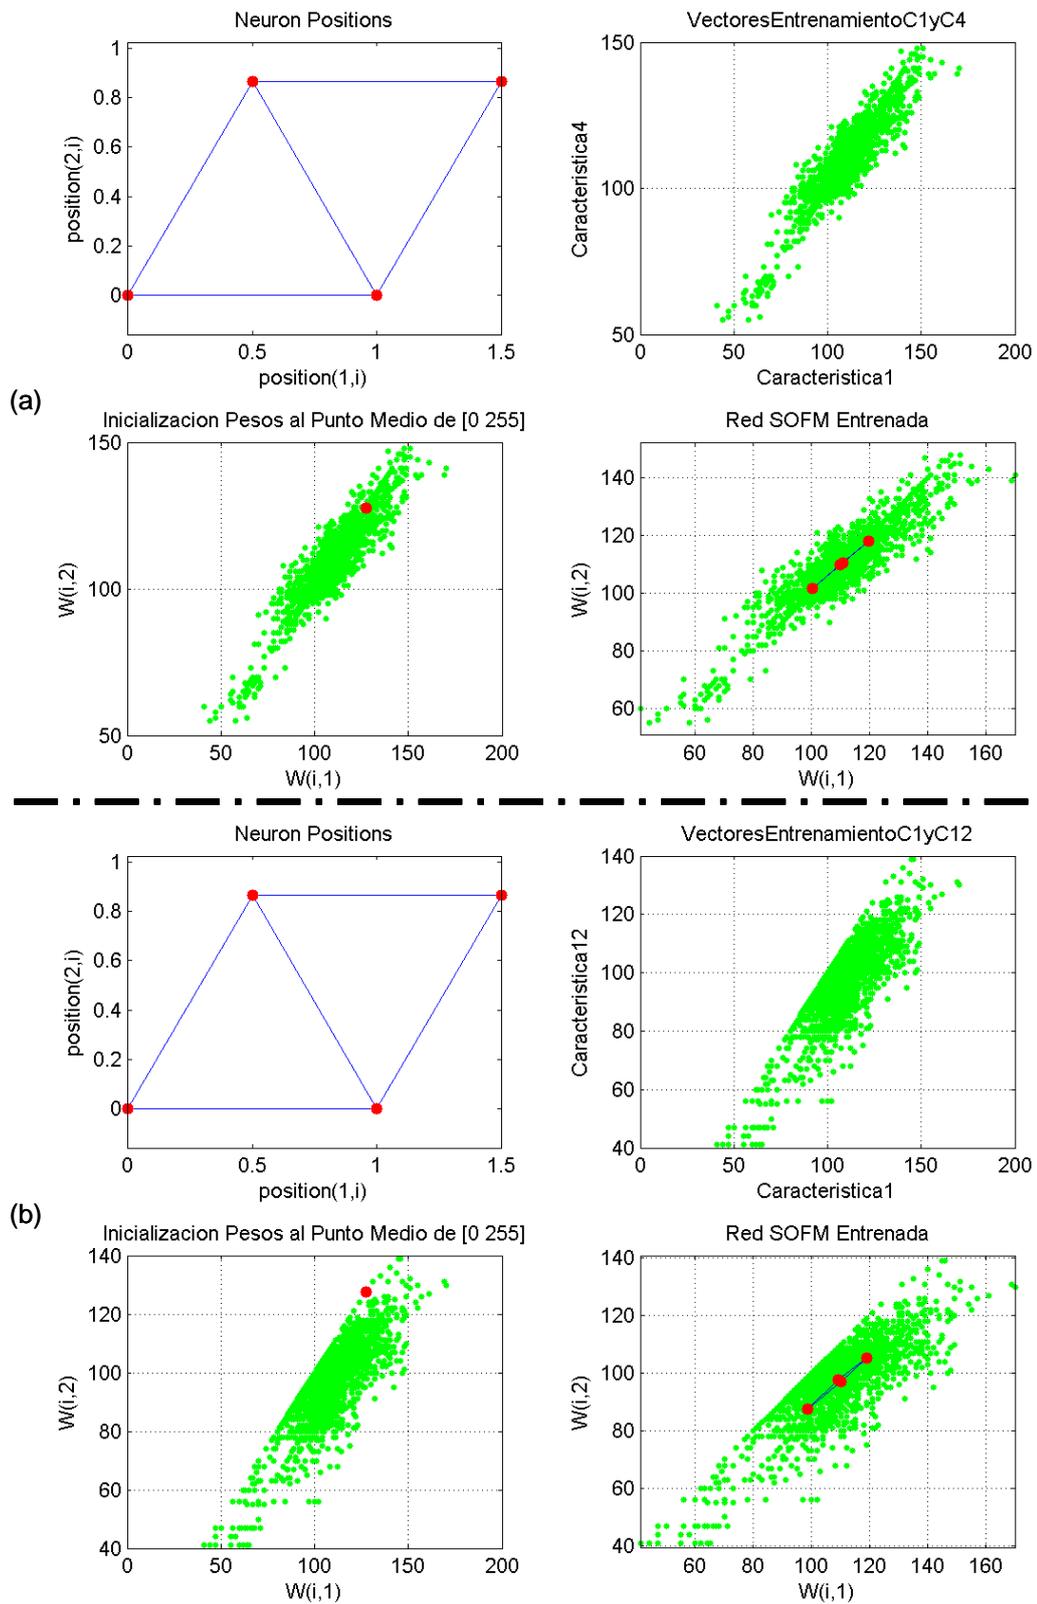
Las cuatro neuronas con topología hexagonal se siguen agrupando en tres clases en el espacio bidimensional de salida. Sin embargo, la clase que más se acerca al defecto de cascarilla no representa esta región, porque la cascarilla tiene valores que oscilan entre 35 y 55 (en la escala de grises [0 – 255]). El conjunto de entrenamiento

que más resalta la clase debida al defecto de cascarilla es el que se puede observar en la figura A.24a. Por otro lado, la utilización de la función distancia “boxdistance” no varia demasiado la capa de salida del mapa autoorganizado.

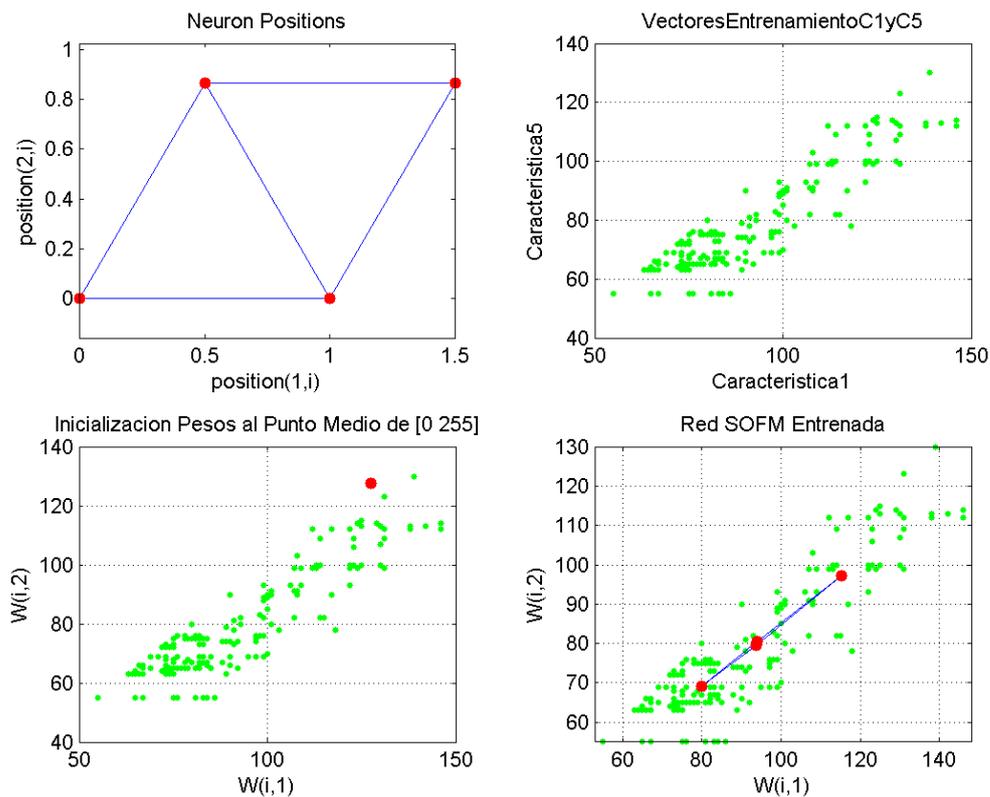
El mapa autoorganizado (capa de salida) que presenta una clase más cercana a la zona de cascarilla es el correspondiente a la red entrenada con el vector de características {C1 y C12} (figura A.24b).

La ultima reducción del conjunto de entrenamiento de la red SOFM se limita a una ventana (14×12) con un defecto de cascarilla en el plano de color verde de la primera imagen RGB => 168 píxeles × 2 características. El plano verde como se explico anteriormente (capítulo 3) es el más apropiado para detectar defectos de cascarilla residual.

En comparación con los vectores de características anteriores, el plano verde proporciona las mejores características para el entrenamiento de las redes. Casi todos los vectores de características, reflejan la existencia de una clase perteneciente a la zona de cascarilla. Los mapas autoorganizados presentan clases un poco más cercanas a la zona de cascarilla (por ejemplo, entrenamiento con características C1 y C5, figura A.25).



**Figura A.24:** (a) SOFM “Box Distance” entrenada con Característica 1 y Característica 4, (b) SOFM “Box Distance” entrenada con Característica 1 y Característica 12



**Figura A.25:** SOFM Ventana defecto cascarilla; Plano Verde; entrenada con Característica 1 y Característica 5

Otras pruebas variando parámetros, con este último conjunto de entrenamiento y utilizando las características C1 y C12, muestran los siguientes resultados:

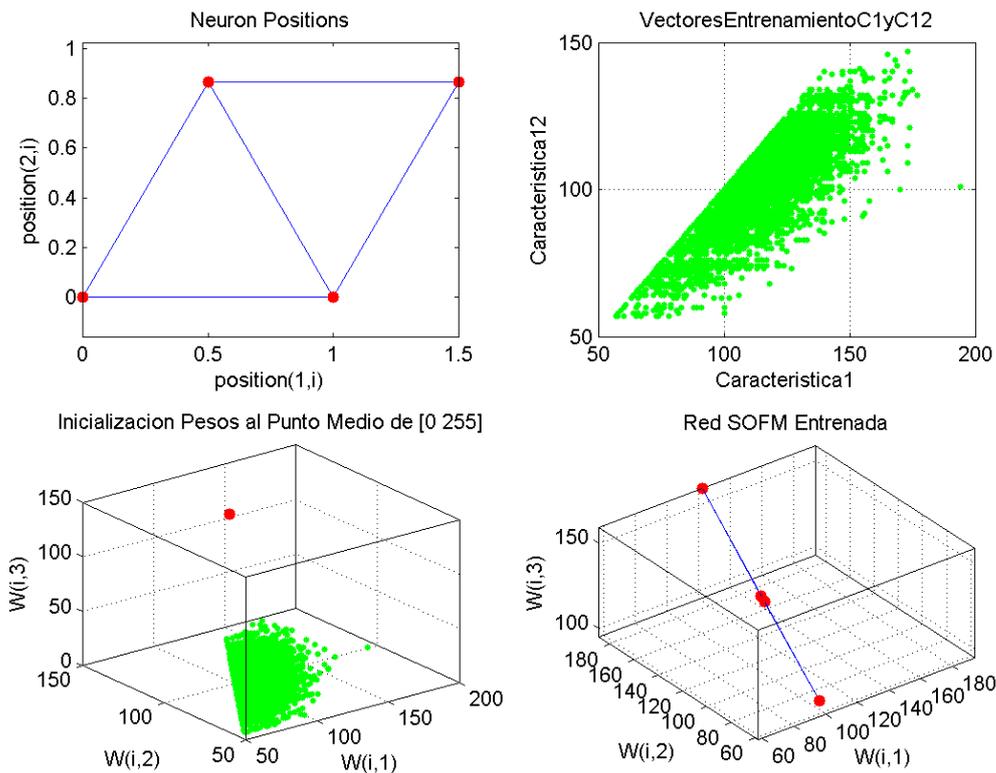
- 1 y 100 épocas de entrenamiento: no se observa diferencia entre entrenar pasando una sola vez el conjunto de entrenamiento o pasándolo 100 veces.
- Entrenamiento disminuyendo los “Pasos en la fase inicial” a 1 (por defecto = 1000) y aumentando a 10000: el primer caso reduce la distancia entre clases y el segundo la aumenta produciendo un mejor mapa autoorganizado.
- Entrenamiento disminuyendo la “Distancia de vecindad en la fase de ajuste” (por defecto = 1) a 0.001 y aumentándola a 100: el primer caso mejora el mapa autoorganizado de salida mientras que el segundo empeora el resultado.

En estas tres pruebas anteriores se han variado también las tasas de aprendizaje, pero no han mostrado mejoras ni variación en los mapas autoorganizados.

Una vez entrenada se prueba la red SOFM con el siguiente conjunto de prueba: mitad del plano de color verde de la primera imagen RGB => 33000 píxeles  $\times$  2 características. La prueba consiste en los siguientes pasos: primero se elige un número aleatorio entre 1 y 33000, segundo se selecciona el vector de características correspondiente a ese número, y finalmente, se prueba la red SOFM. La red muestra a cual de las cuatro clases pertenece el vector de características elegido de forma aleatoria. Los resultados muestran que es posible segmentar y clasificar la imagen a partir de este método, pero es necesario afinar más en el diseño de la red, para que el mapa autoorganizado (capa de salida) represente una clase más cercana a la zona de la cascarilla. Con este método se consigue directamente clasificar una imagen e implícitamente segmentarla.

La última prueba es relativa a la reducción de dimensionalidad característica de las redes SOFM. Las pruebas anteriores han utilizado sólo vectores de características de dos dimensiones y capas de salida de dos dimensiones, por lo tanto no existe reducción de dimensión. En este caso se pretende mejorar el entrenamiento de la red y mostrar como la red SOFM reduce el espacio de entrada (12 dimensiones) al espacio de salida tridimensional.

Así pues, se han utilizado datos del plano de color verde (conjunto de entrenamiento completo) debido a que son los que mejor entrenan las redes SOFM para este problema concreto de detección de cascarilla. Los resultados obtenidos son aproximadamente los mismos que en los entrenamientos anteriores, no se aprecia diferencia al reducir la dimensión del espacio de entrada (figura A.26).



**Figura A.26:** Reducción de dimensión  $12 \Rightarrow 3$ . Solo se muestran dos dimensiones del vector de características en la segunda grafica debido a que no se pueden visualizar todas las dimensiones. El rango de entrada ha sido  $[0 \ 255]$  y los vectores solo se han pasado 1 vez

#### A.2.4.2. Método 2. Imagen directa

El siguiente método se basa en extraer directamente de la imagen ventanas para el entrenamiento de la red. Las pruebas utilizan el plano de color verde debido a que este plano facilita la detección de una clase perteneciente a los defectos de cascarilla residual.

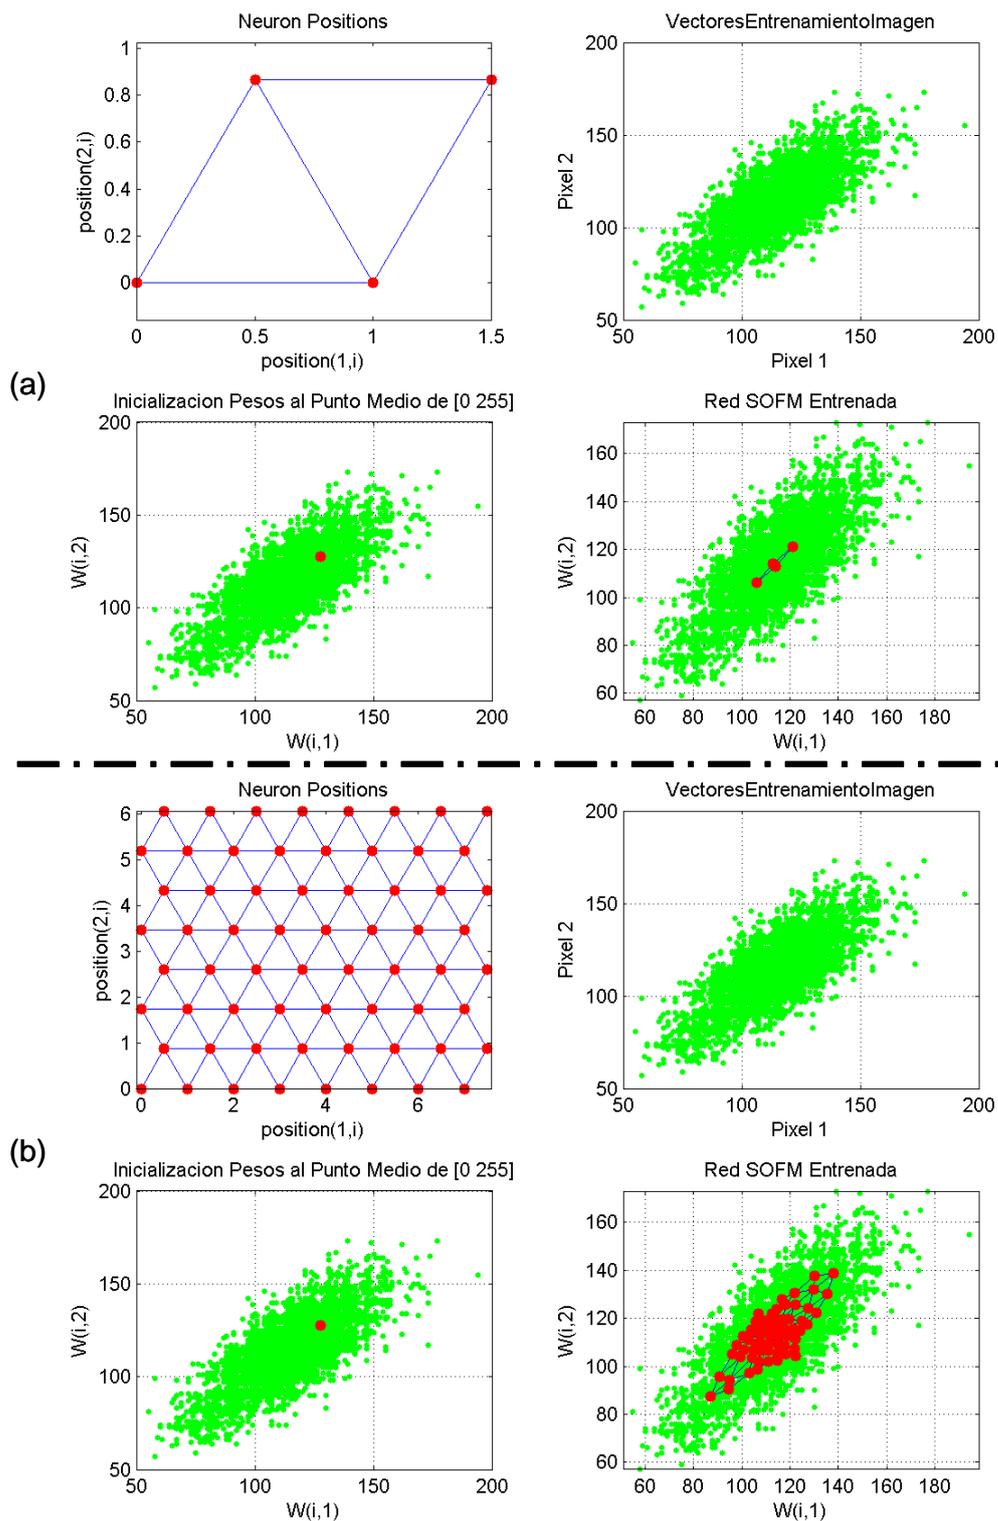
El siguiente experimento utiliza una parte del plano de color verde ( $128 \times 256$  píxeles). De esta imagen obtenemos pequeñas ventanas  $2 \times 1$ , que forman los vectores de características bidimensionales (capa de entrada). Cada entrenamiento se ha

realizado con un número distinto de neuronas de salida con el objetivo de estudiar el efecto de aumentar el número de neuronas de la capa de salida (figura A.27).

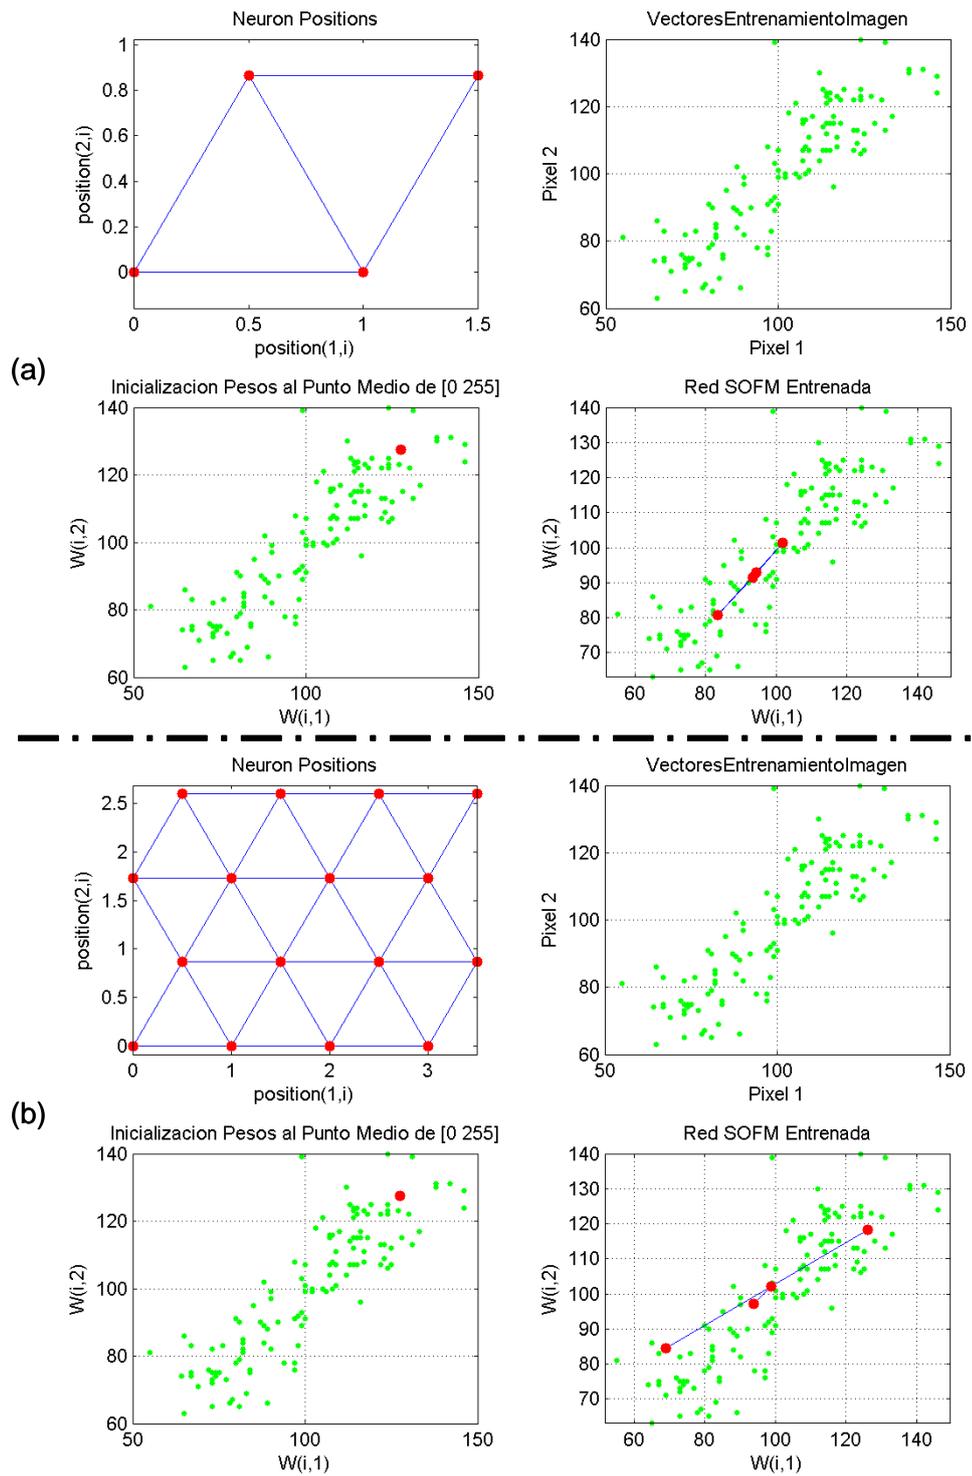
Los resultados obtenidos no mejoran las redes entrenadas con el método anterior. Con cuatro neuronas en la capa de salida siguen apareciendo tres clases en el mapa autoorganizado. También, al aumentar el número de neuronas no mejora el entrenamiento y si aumenta mucho los recursos del sistema de cálculo. Únicamente, a medida que hay más neuronas una neurona se acerca más a la zona de cascarilla.

El conjunto de entrenamiento anterior no produce los resultados deseados. Por este motivo se realiza una prueba con una pequeña imagen  $16 \times 16$  que posee un defecto de cascarilla. La siguiente figura A.28 muestra el entrenamiento de dos redes SOFM con un vector de características de 2 píxeles en la capa de entrada, y 4 y 16 en la capa de salida. Con cuatro y dieciséis neuronas en la capa de salida siguen apareciendo tres clases en el mapa autoorganizado. Así pues, al aumentar el número de neuronas no mejora el entrenamiento y si aumentan los recursos necesarios del sistema de cálculo.

Finalmente, las dos últimas pruebas utilizan la imagen que se obtiene tras realizar un ajuste de intensidad al plano de color verde para aumentar el contraste. El primer caso utiliza una imagen  $128 \times 256$  (fig. A.29a) y el segundo un pequeño recorte ( $16 \times 16$ ) de la imagen anterior con un defecto de cascarilla (fig. A.29b).

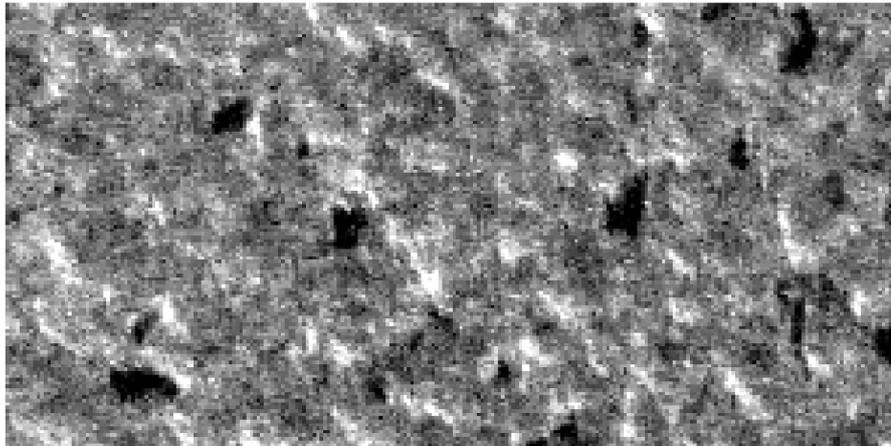


**Figura A.27:** (a) Red SOFM entrenada con vector de características formado por dos píxeles (capa de entrada) de la imagen (plano de color verde) y 4 neuronas en la capa de salida, (b) Igual que el caso (a) excepto que la capa de salida posee 64 neuronas

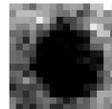


**Figura A.28:** Red SOFM entrenada con vector de características formado por dos píxeles (capa de entrada) de una pequeña imagen 16×16 (con defecto de cascarilla) y 4 neuronas en la capa de salida, (b) Igual que el caso (a) excepto que la capa de salida posee 16 neuronas

### C2AjusteInPColorVerdeRecorte



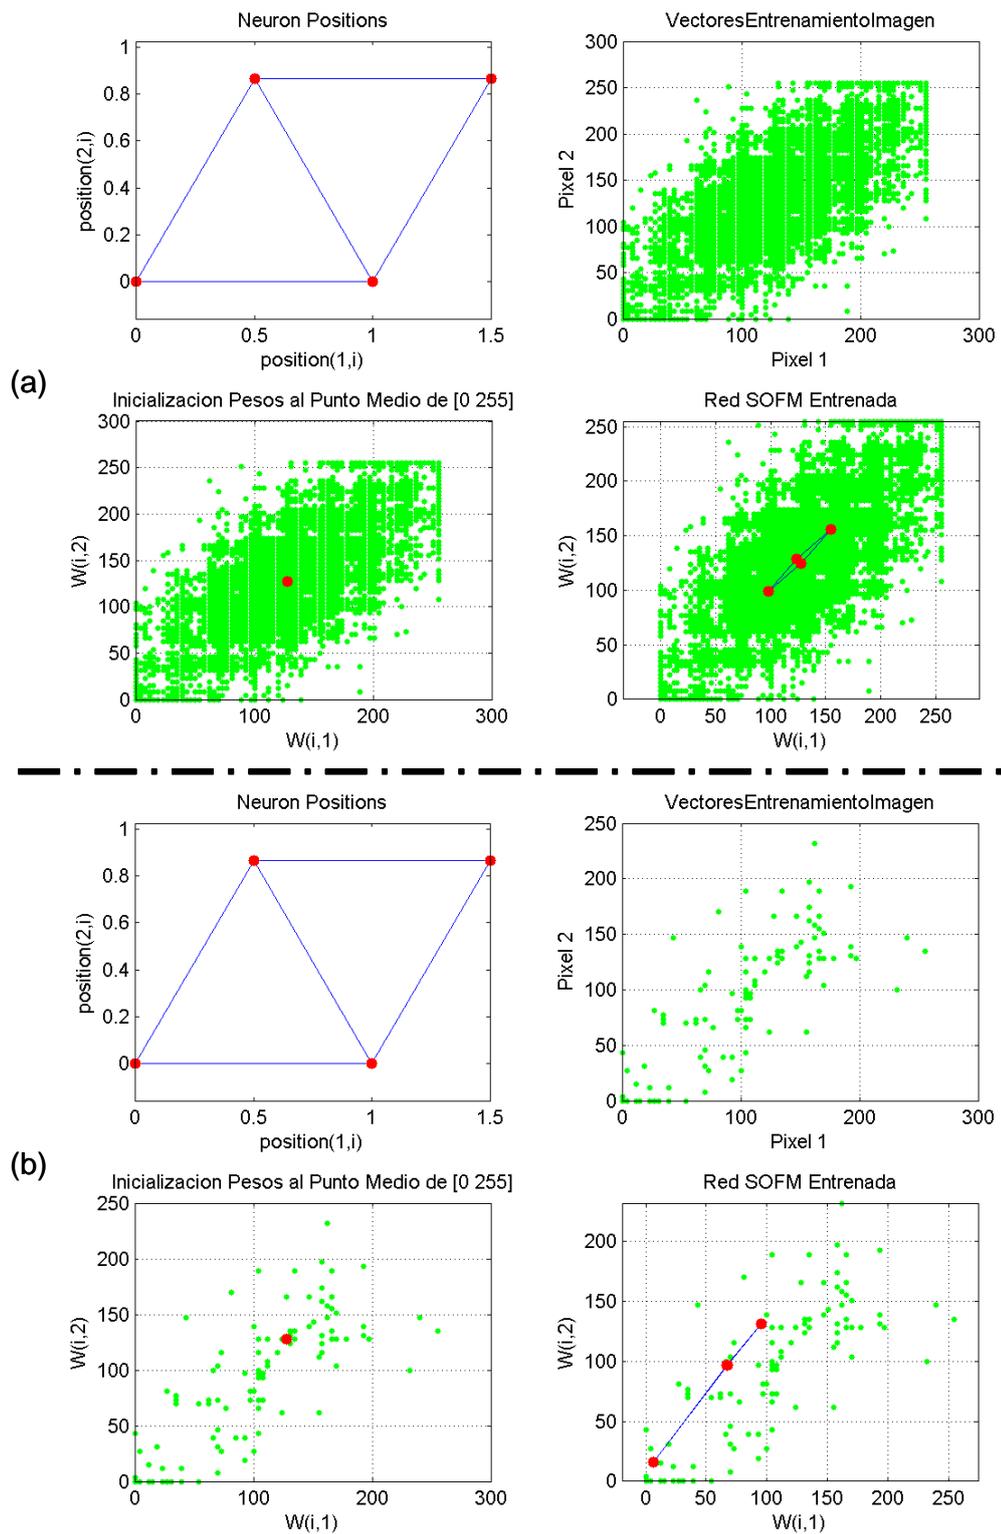
(a)



(b)

**Figura A.29:** (a) Imagen tras realizar un ajuste de intensidad en el plano de color verde, (b) Imagen recortada de la anterior que contiene un pequeño defecto de cascarilla

En el primer caso, el entrenamiento muestra 3 clases y no mejoran los resultados de entrenamientos anteriores (fig. A.30a). En el segundo caso (fig. A.30b), el mapa autoorganizado muestra tres clases. Una de ellas, la más cercana al origen, es la correspondiente a cascarilla residual. Finalmente, se ha conseguido un mapa autoorganizado que es capaz de clasificar los píxeles de futuras imágenes en tres clases: “cascarilla”, “sombras o ruido” y “acero”. Segmentando implícitamente la imagen en tres regiones.



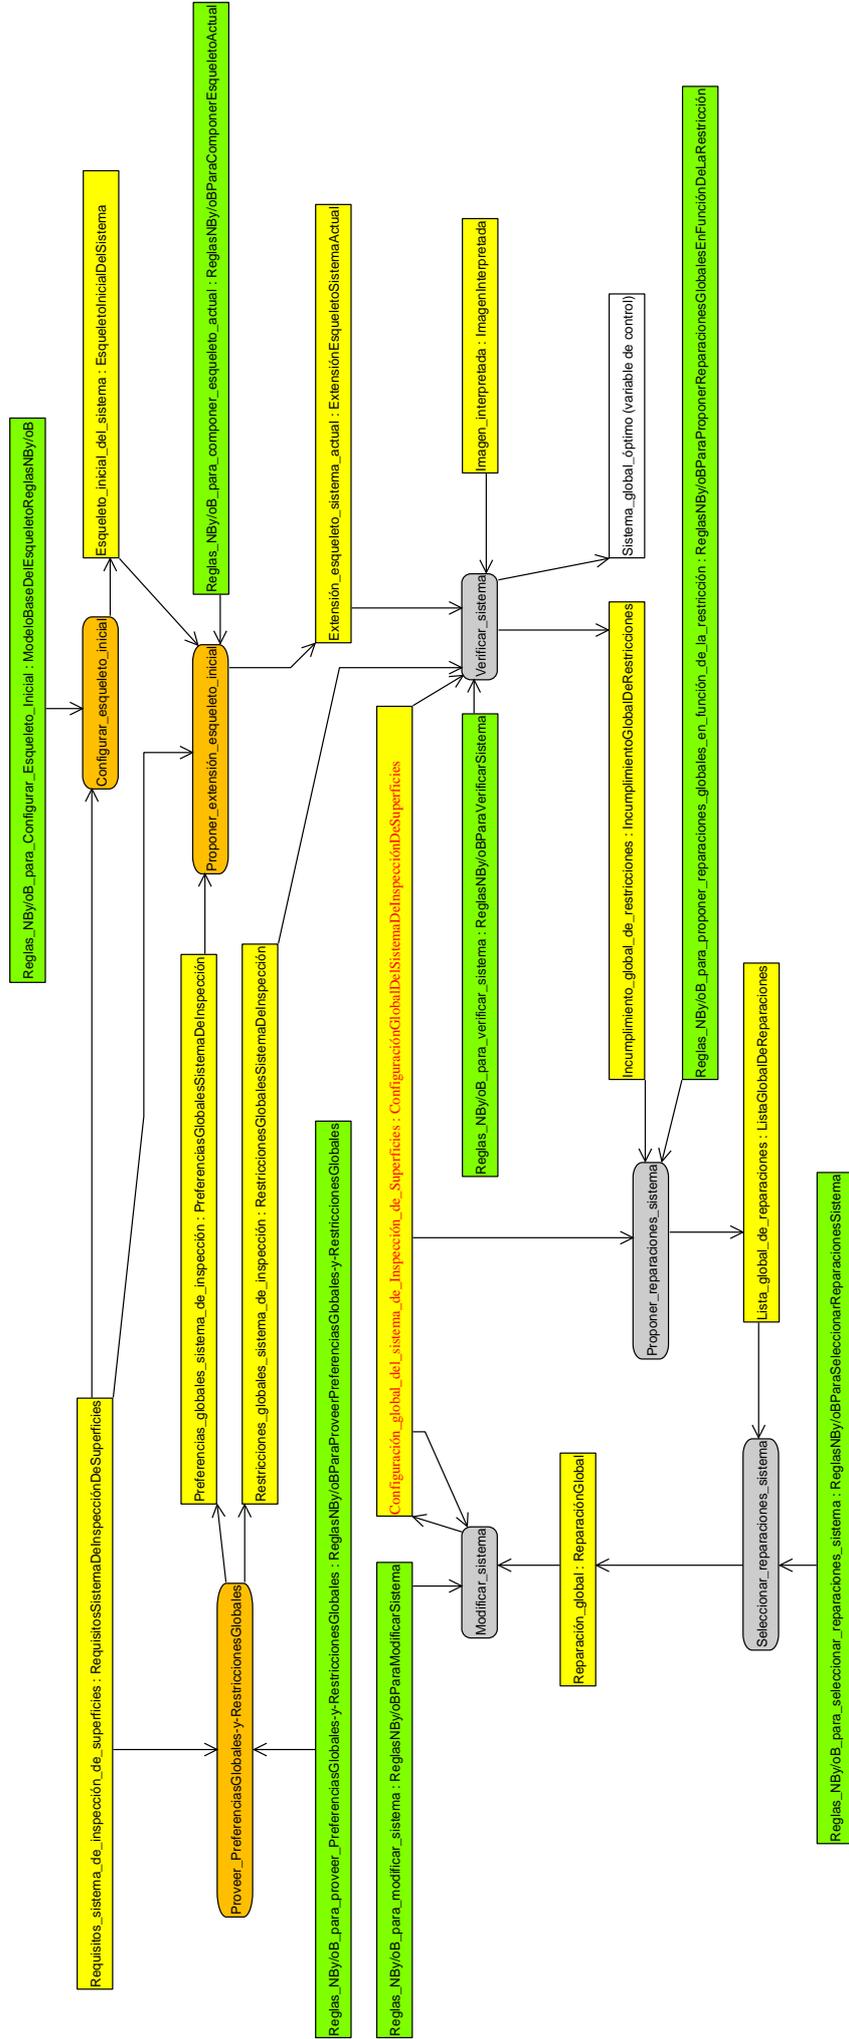
**Figura A.30:** (a) Vector con dos características (2 píxeles), 4 neuronas de salida y 1 época de entrenamiento (imagen  $128 \times 256$ ), (b) Igual que (a) pero en este segundo caso se utiliza un pequeño recorte ( $16 \times 16$ ) de la imagen utilizada en (a)



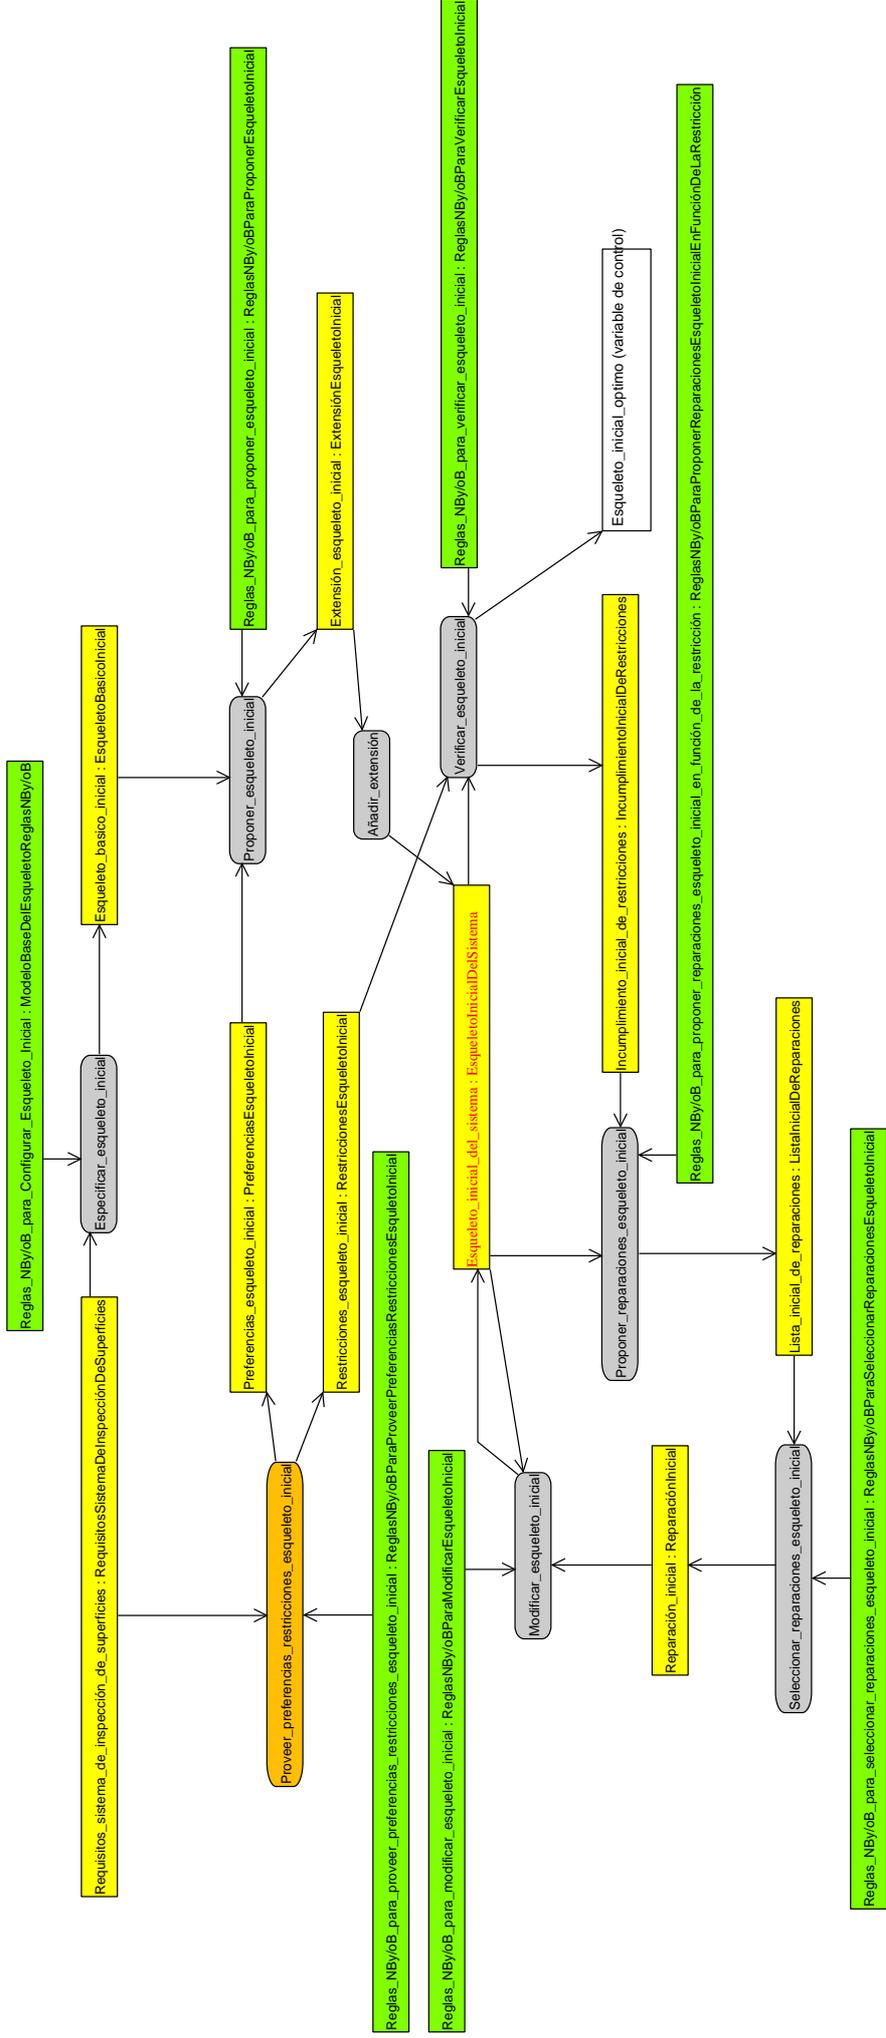
## **Apéndice B**

### **Diagramas de actividad de la arquitectura ARDIS**

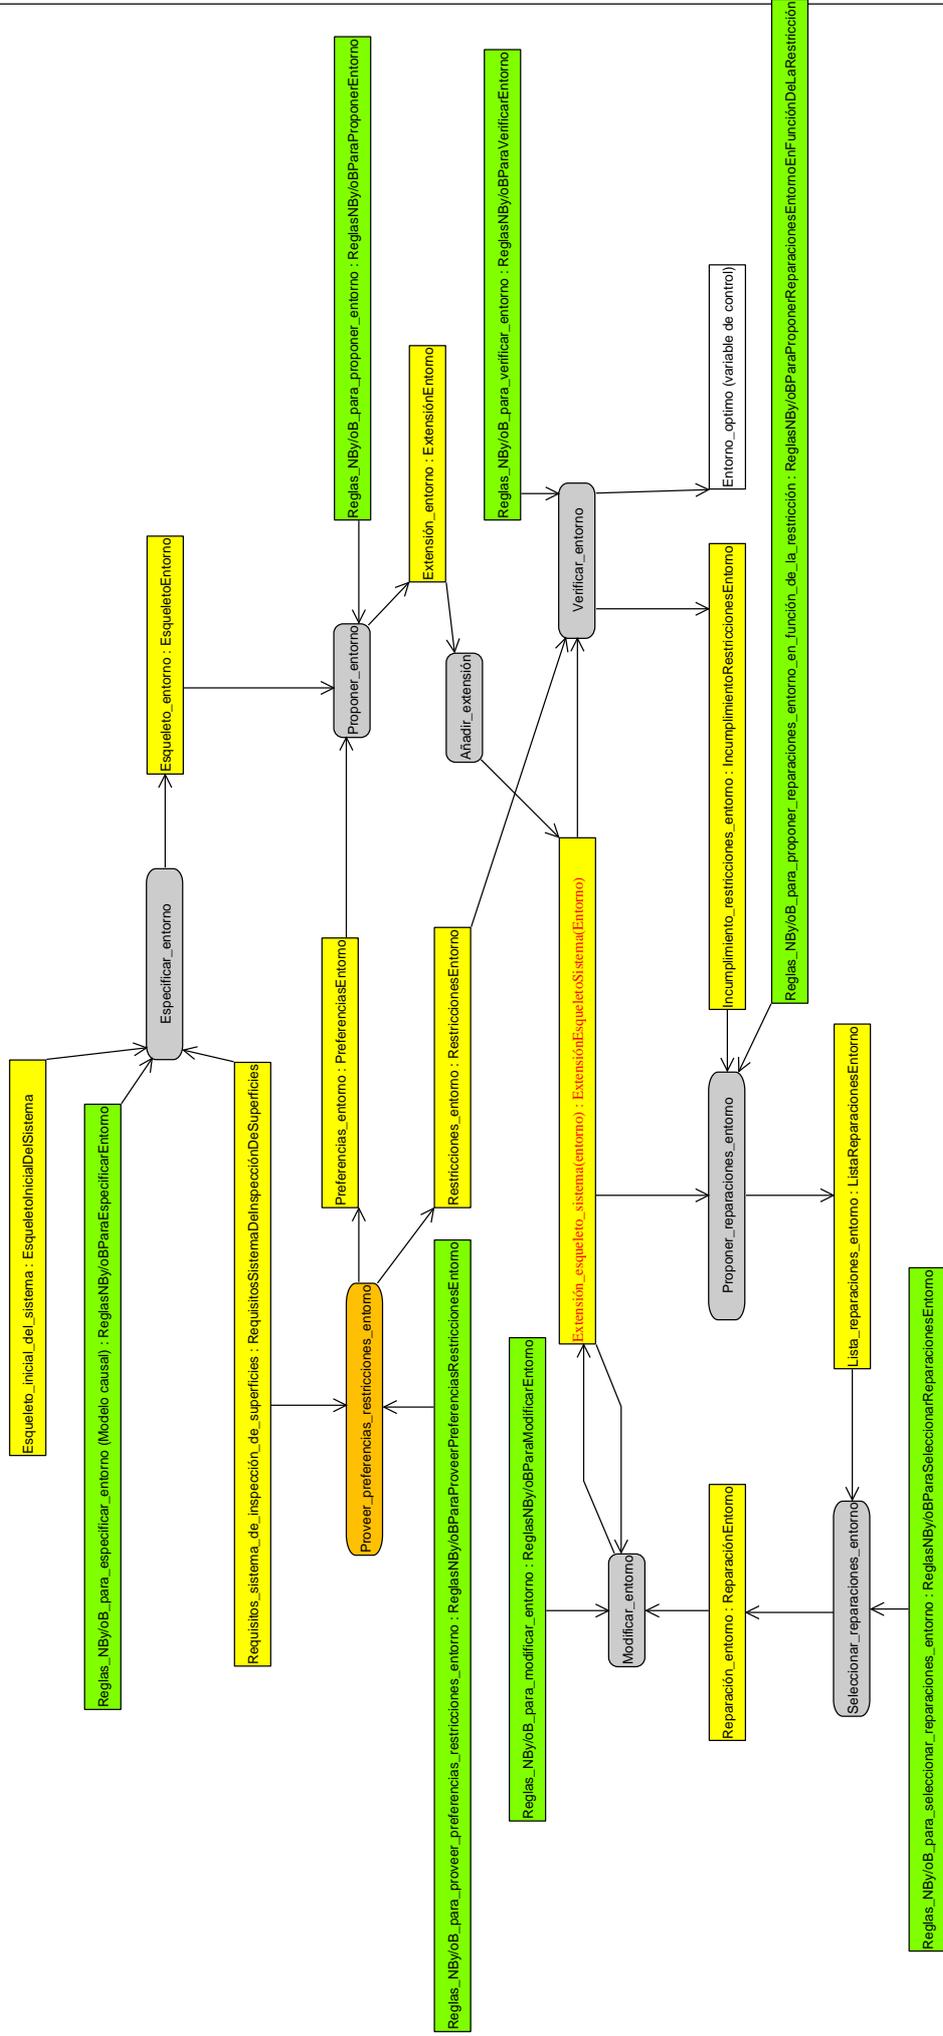
01DA\_TareasDeConfiguraciónDeInspecciónSuperficial\_FSM proponer-y-revisar (1)

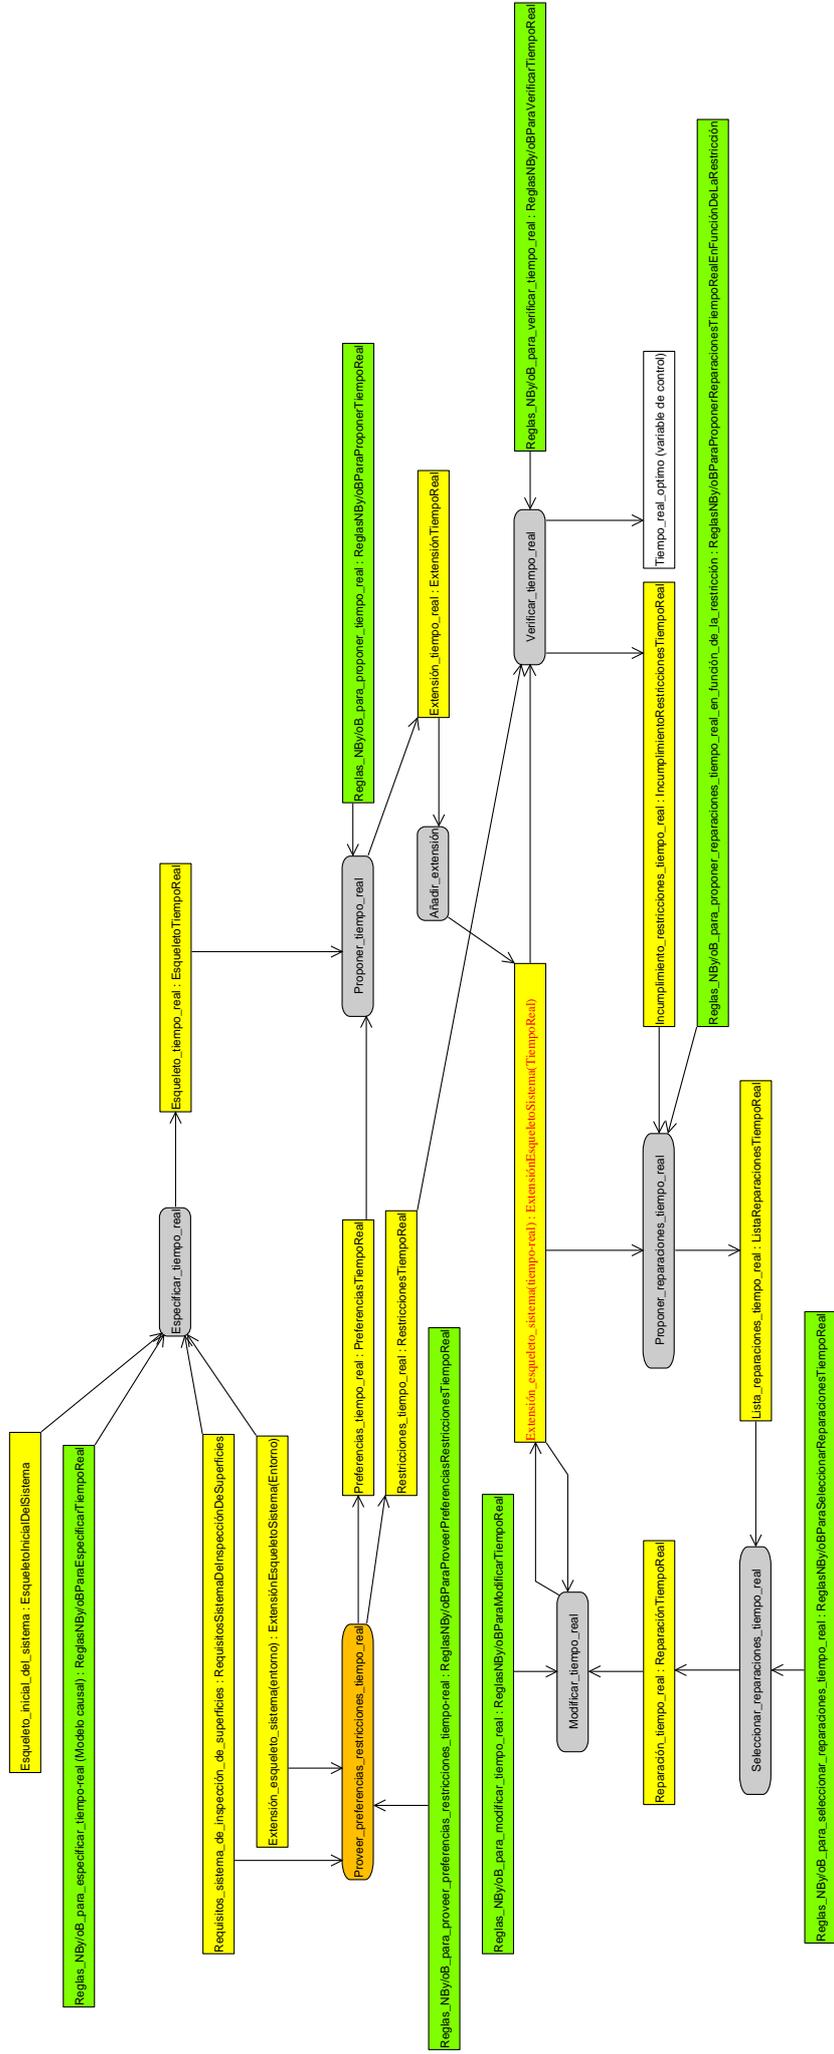


T1DA\_SubtareaConfigurarEsqueletoInicial\_FSMproponer-y-revisar (2)

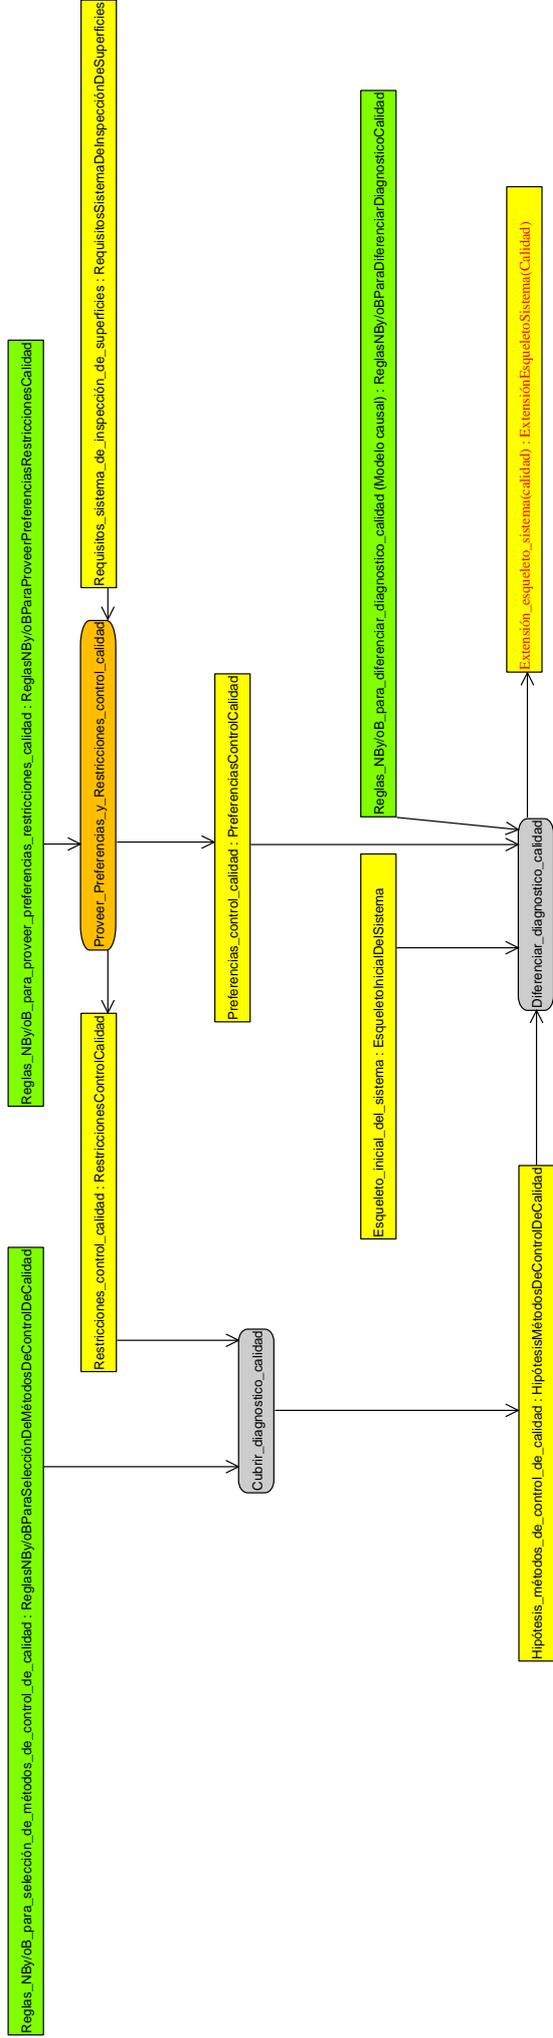


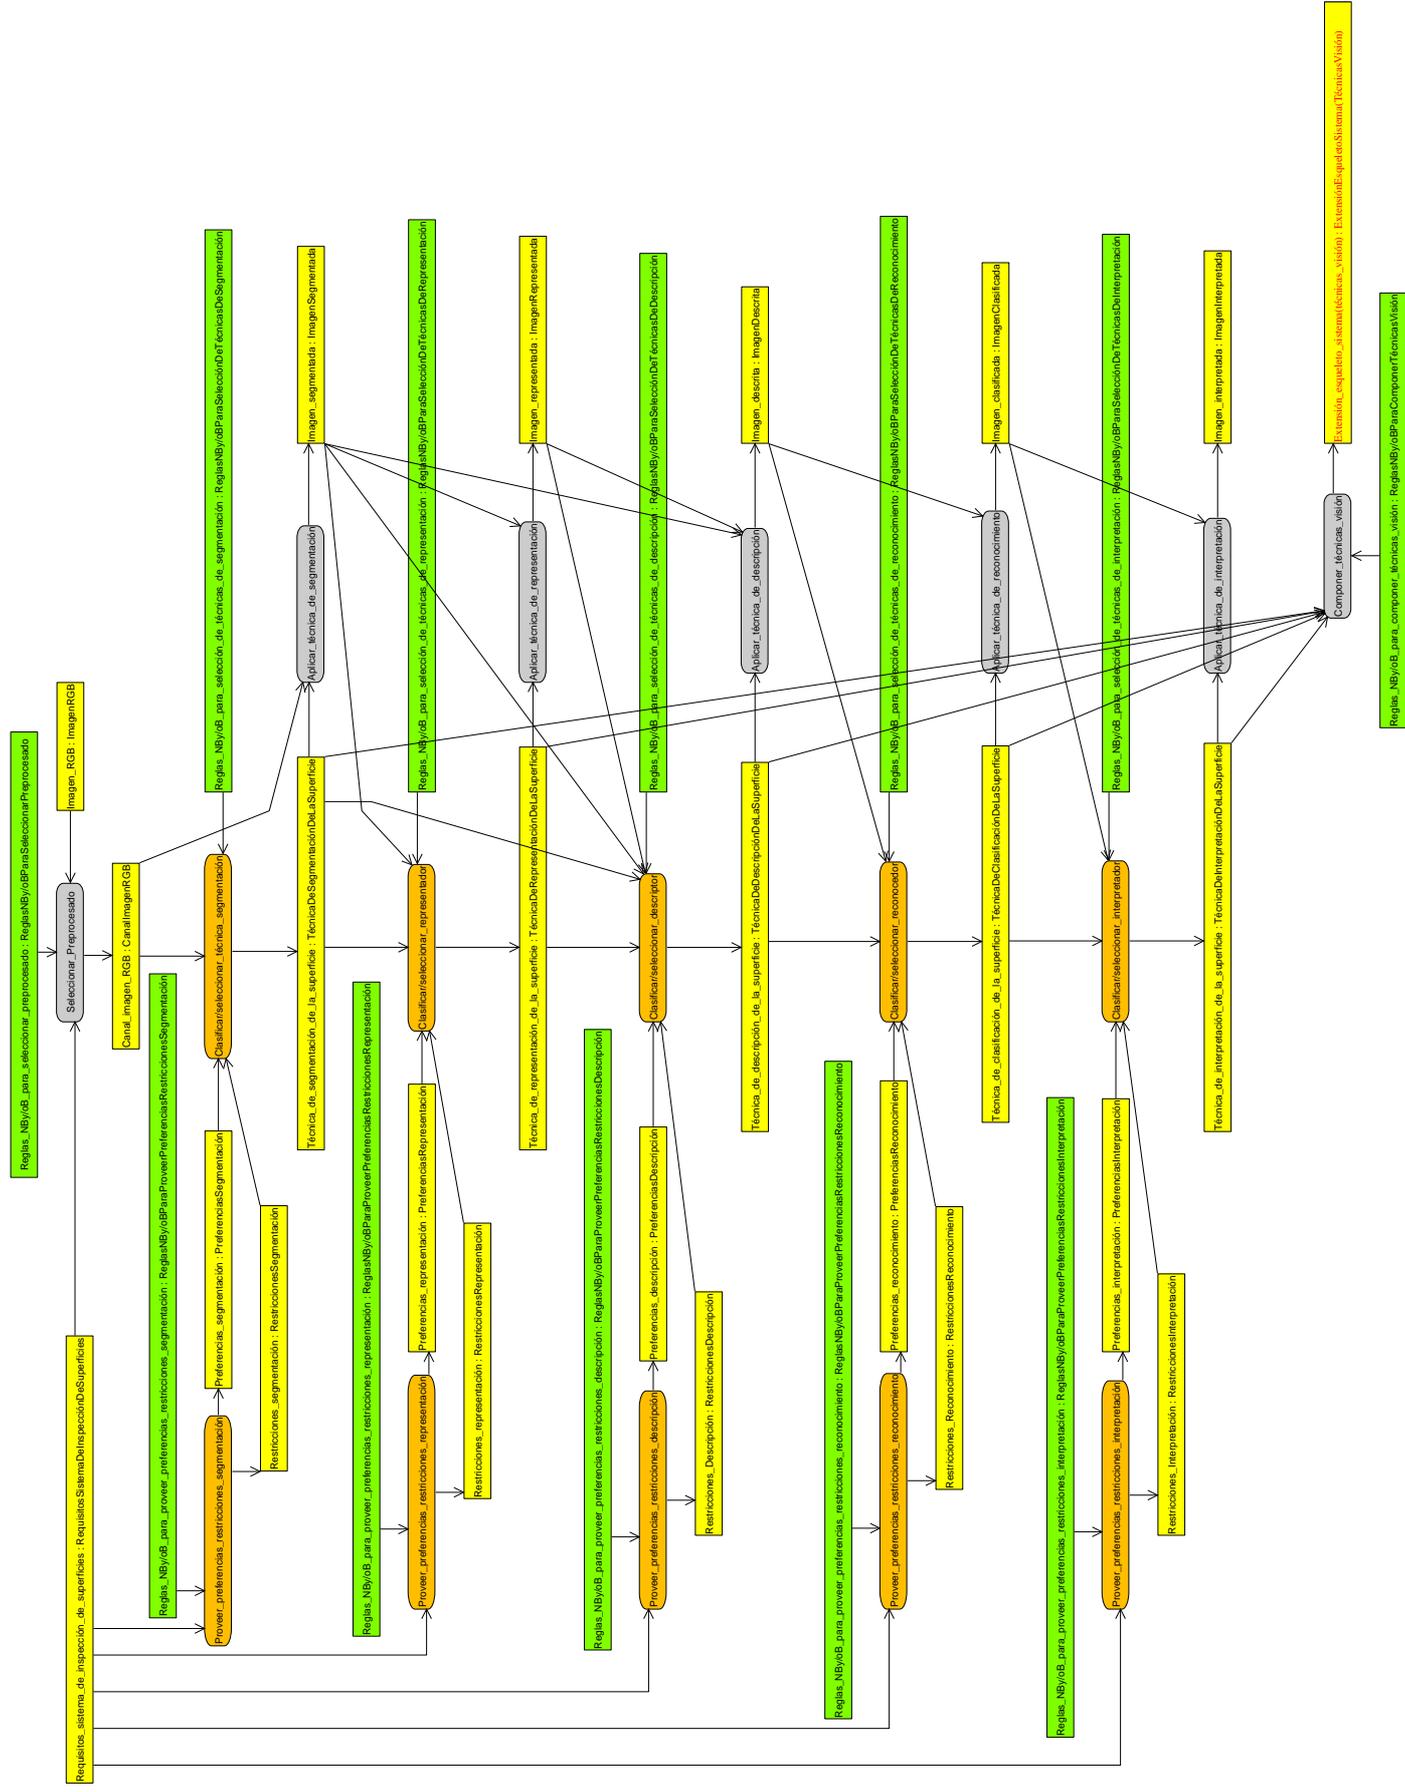




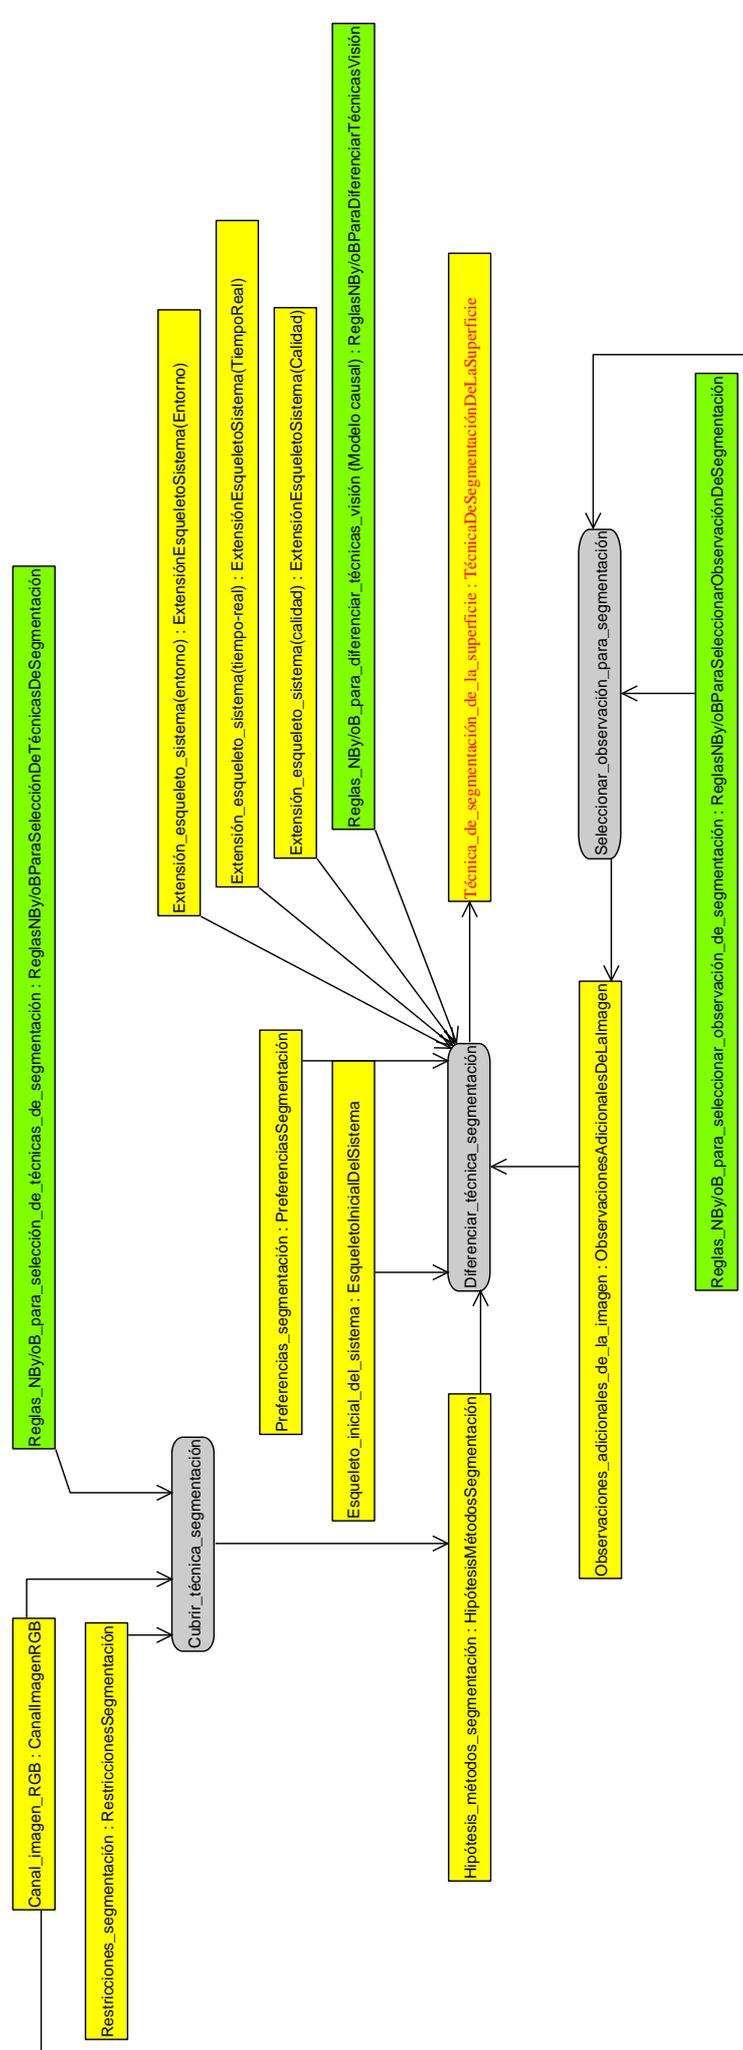


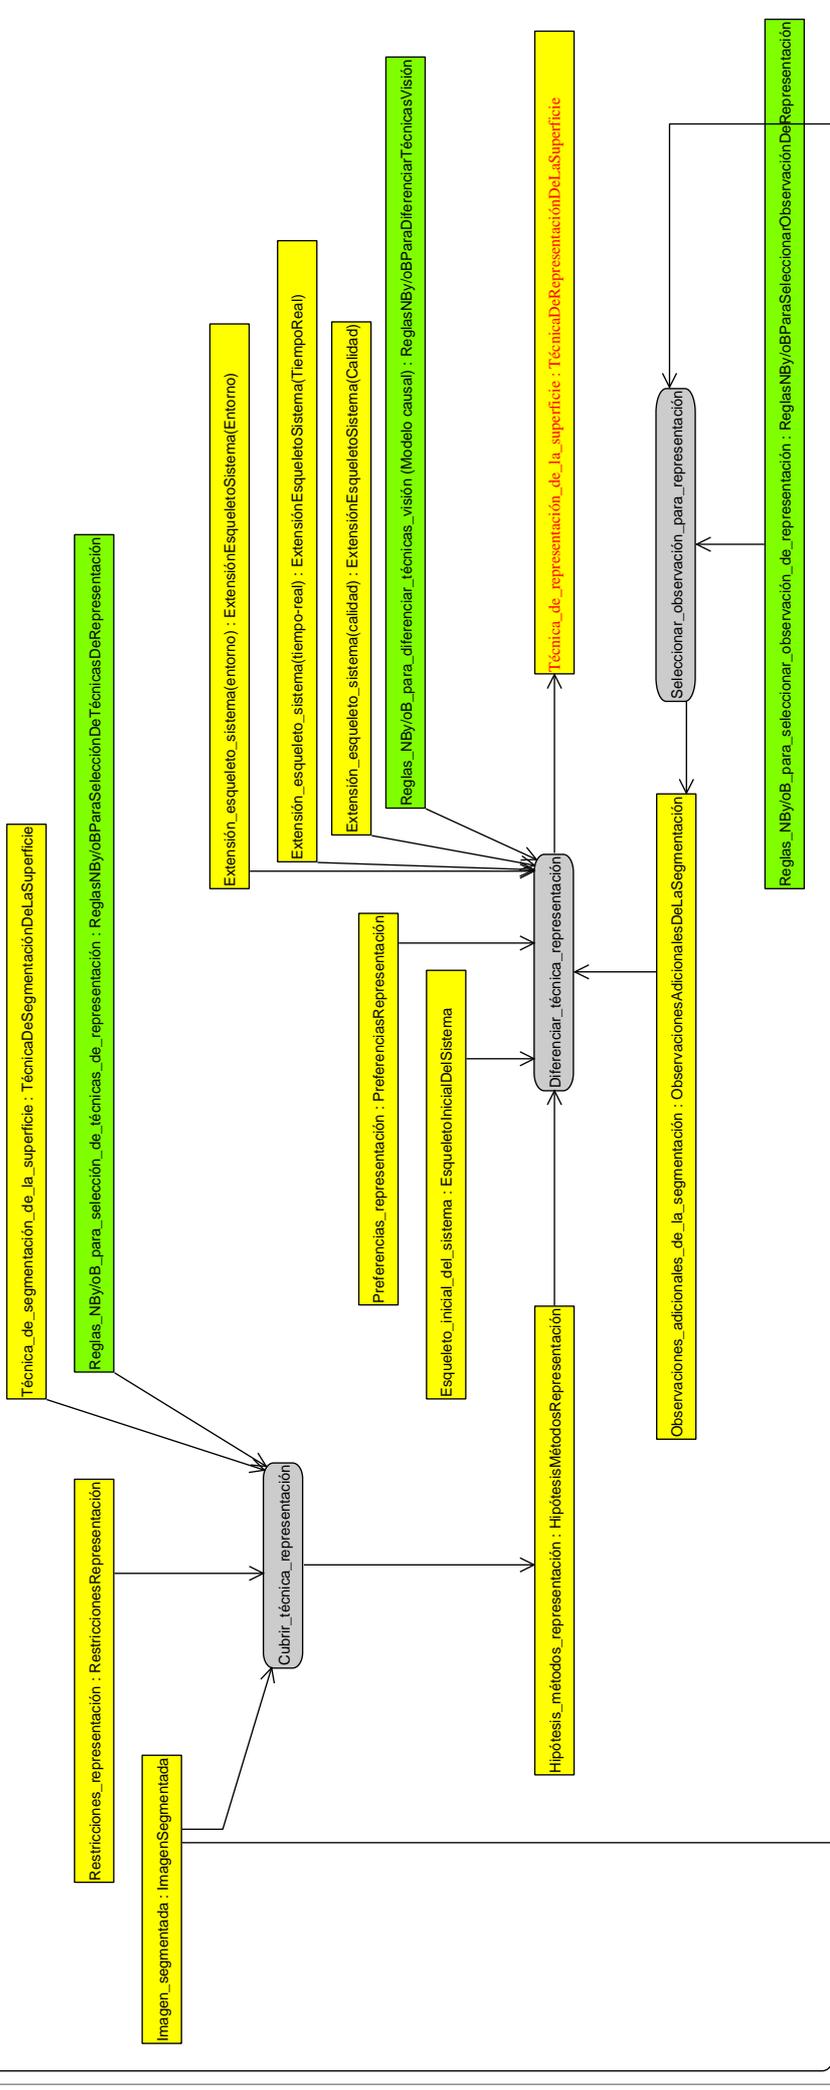
23DA\_SubareaSeleccionarDiagnosticoCalidad\_PSM cubrir-y-diferenciar





31DA\_SubtareaClasificar/seleccionarTécnicaSegmentación\_PSM cubrir-y-diferenciar

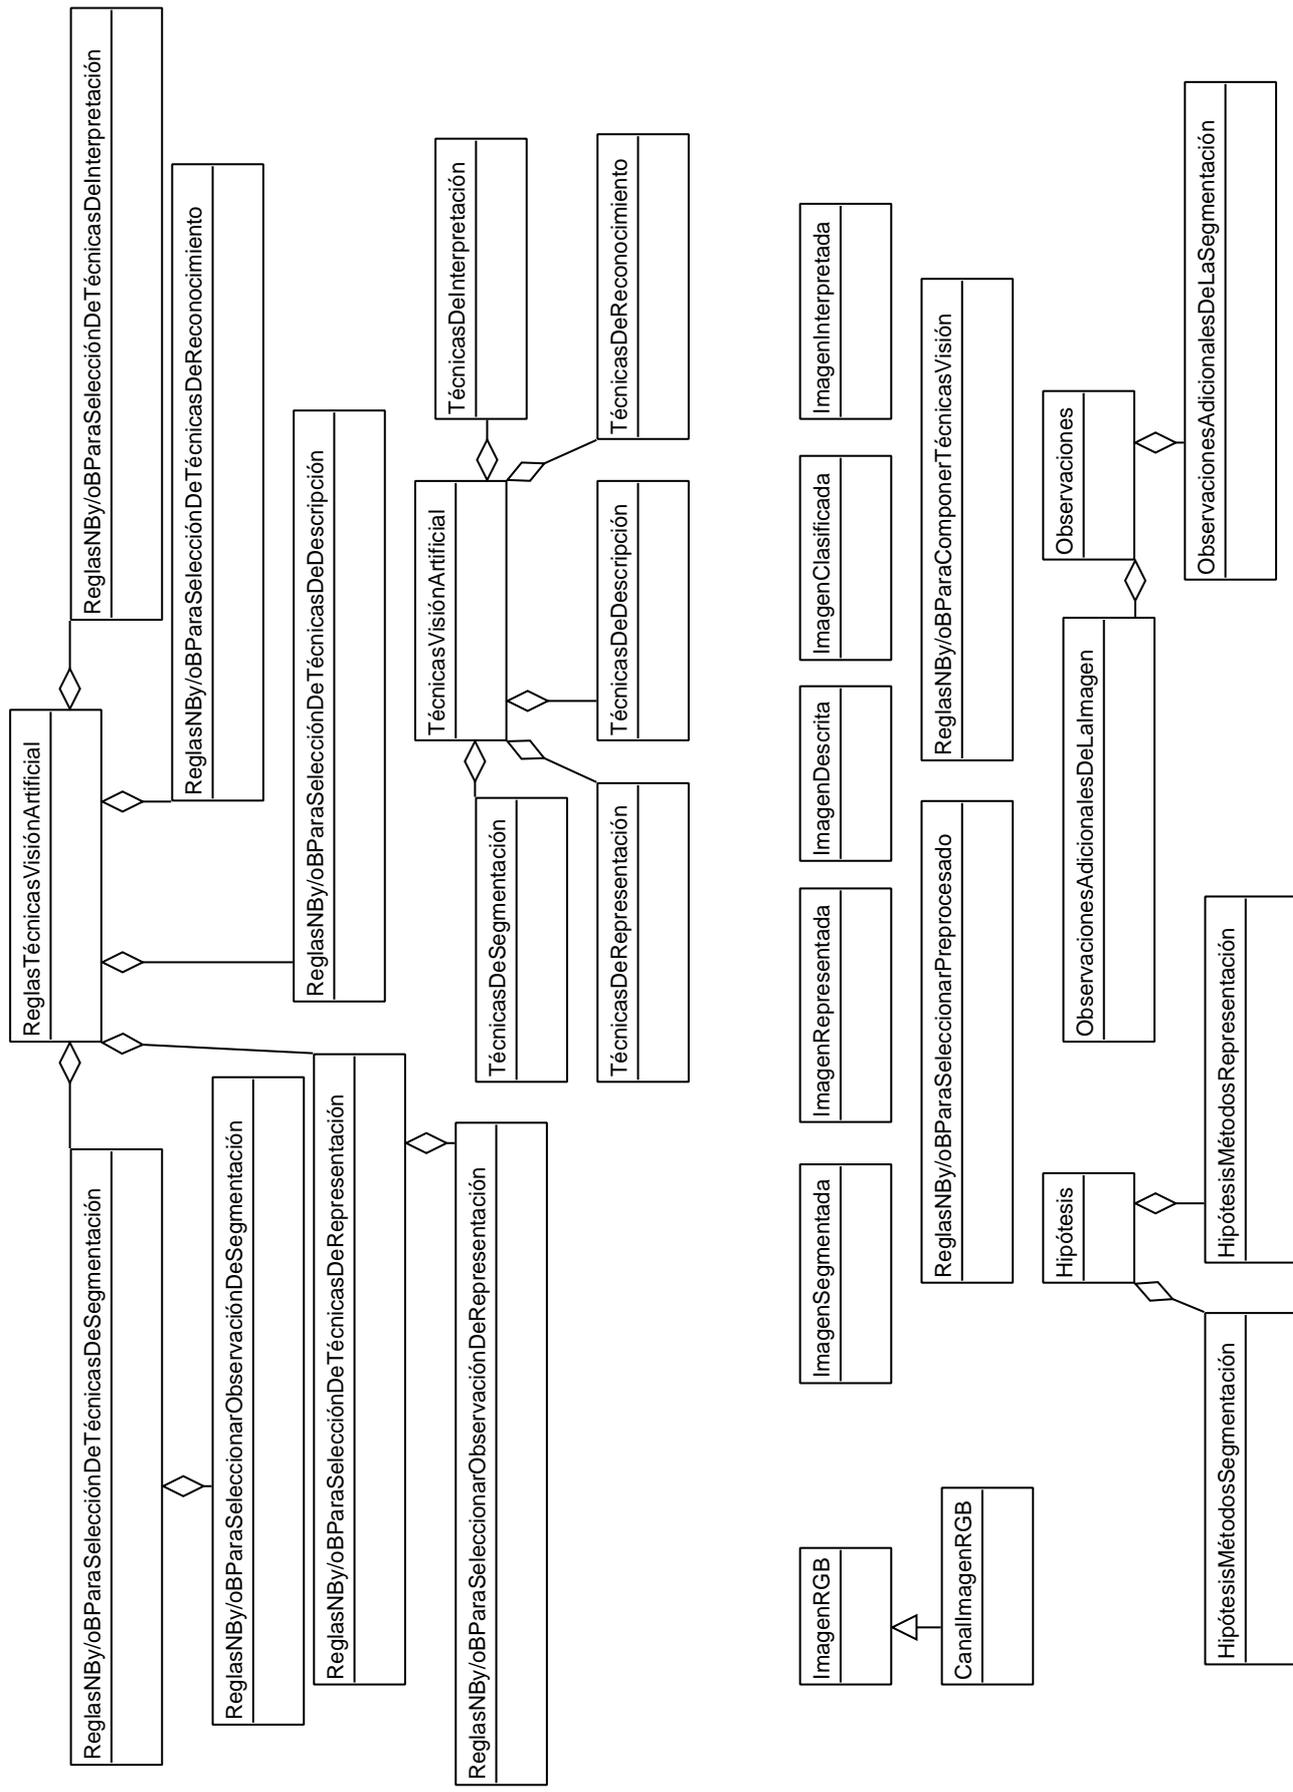




## Apéndice C

### Diagramas de clases de la arquitectura ARDIS





03DC\_SubtareaSeleccionarDiagnosticoCalidad\_DominioDeLaAplicación\_y\_conocimientoDelDominio(reglas)

ReglasNBy/oBParaSelecciónDeMétodosDeControlDeCalidad

HipótesisMétodosDeControlDeCalidad

04DC\_TipoDeDatosSistemaDeInspecciónSuperficial\_DominioDeLaAplicación\_y\_conocimientoDelDominio

TipoDeDatosBorrosoBajoMedAlto

-BorrosoBajoMedAlto:string={bajo, medio, alto}

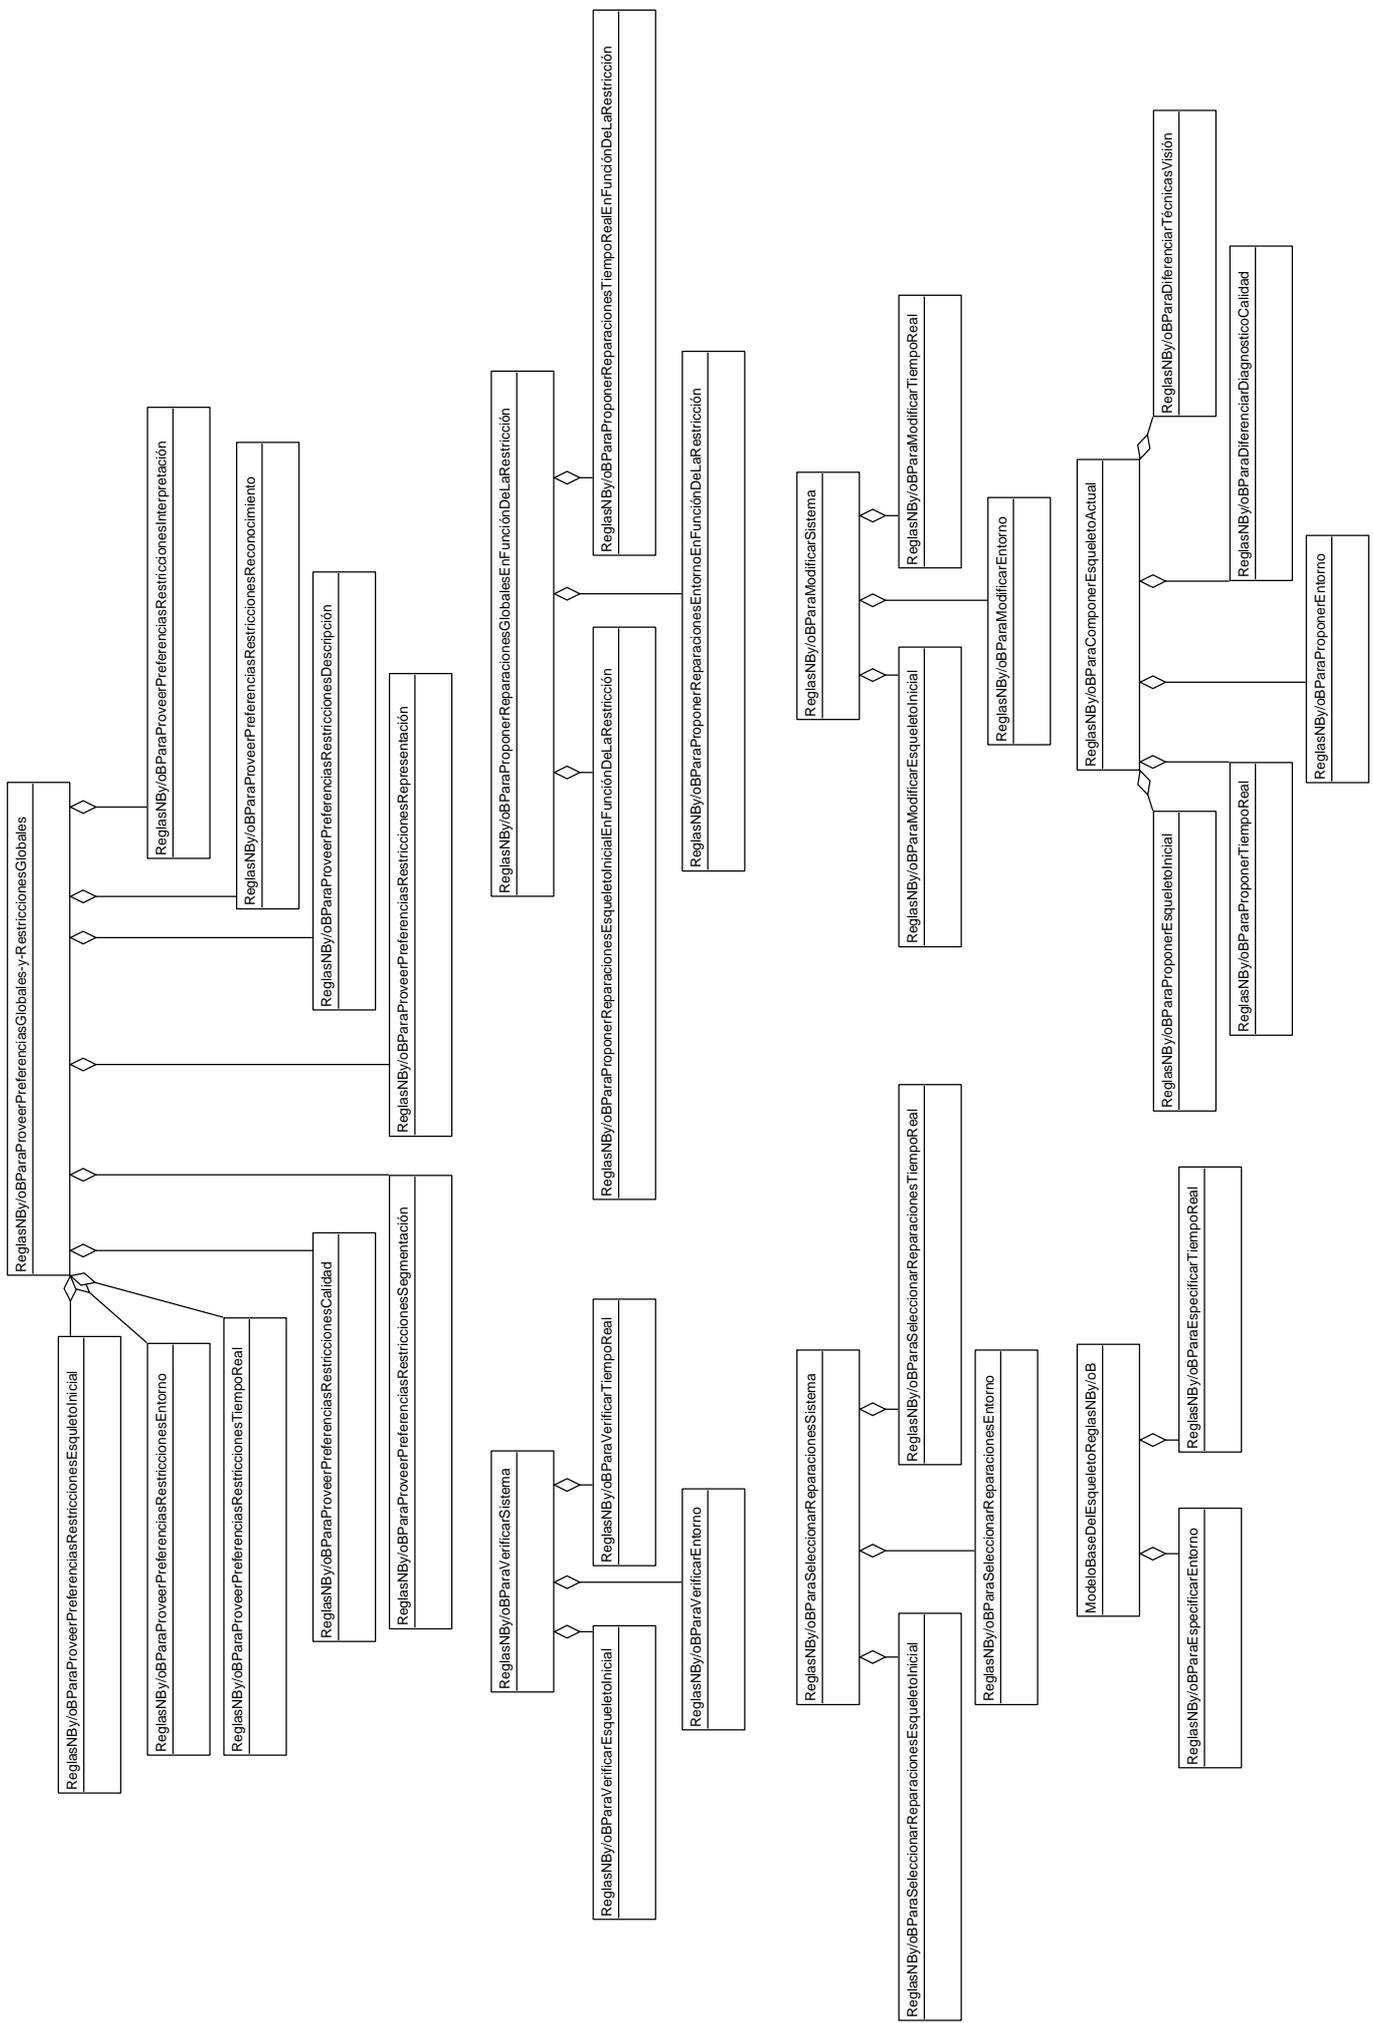
TipoDeDatosBorrosoMuyGrandeNormalPequeñoMuyPequeño

-BorrosoMuyGrandeNormalPequeñoMuyPequeño:string={muy grande, grande, normal, pequeño, muy pequeño}

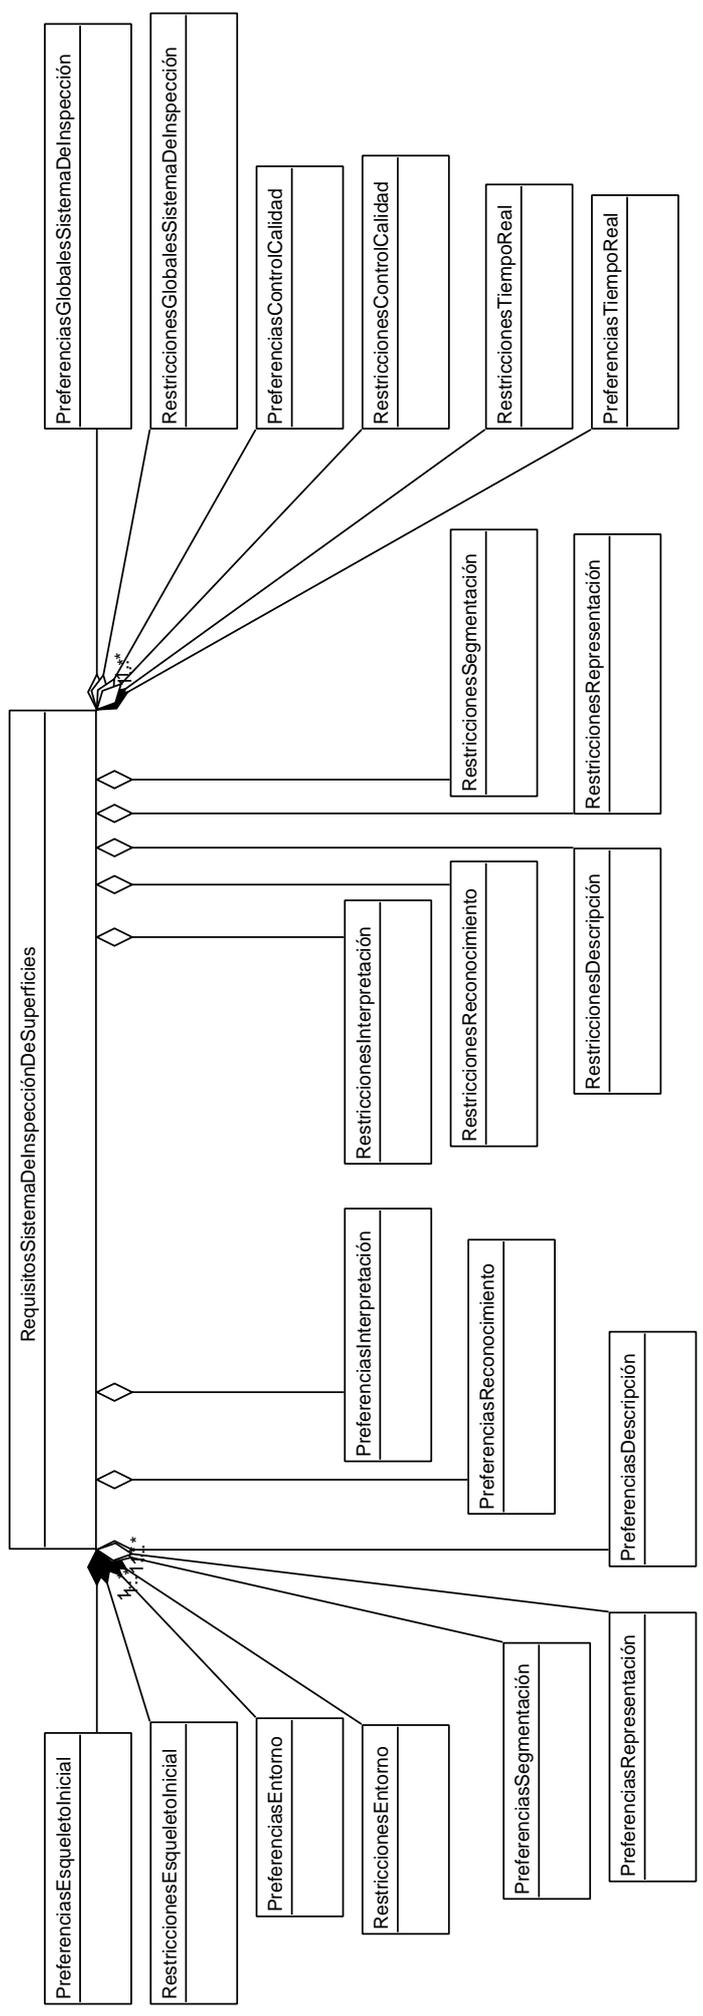
TipoDeDatosFuerteMediaSuave

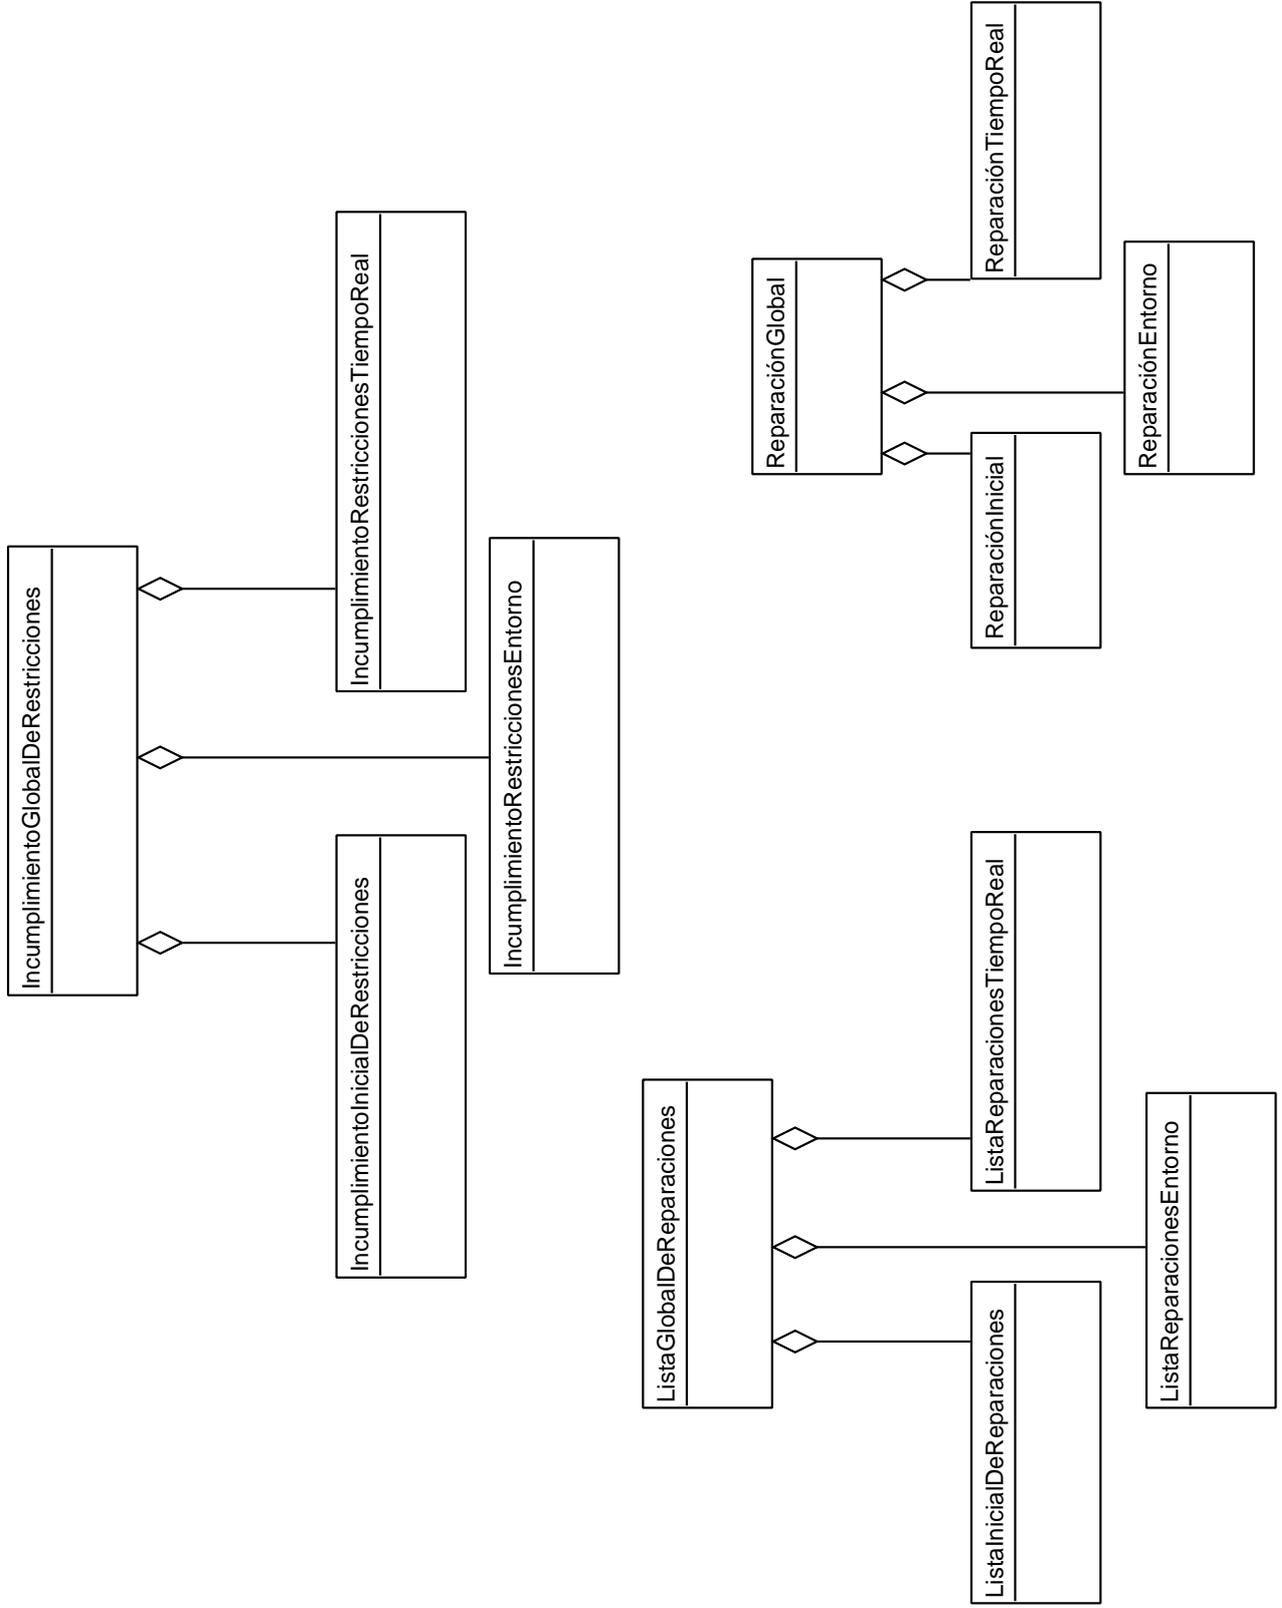
-BorrosoFuerteMediaSuave:string={fuerte, media, suave}

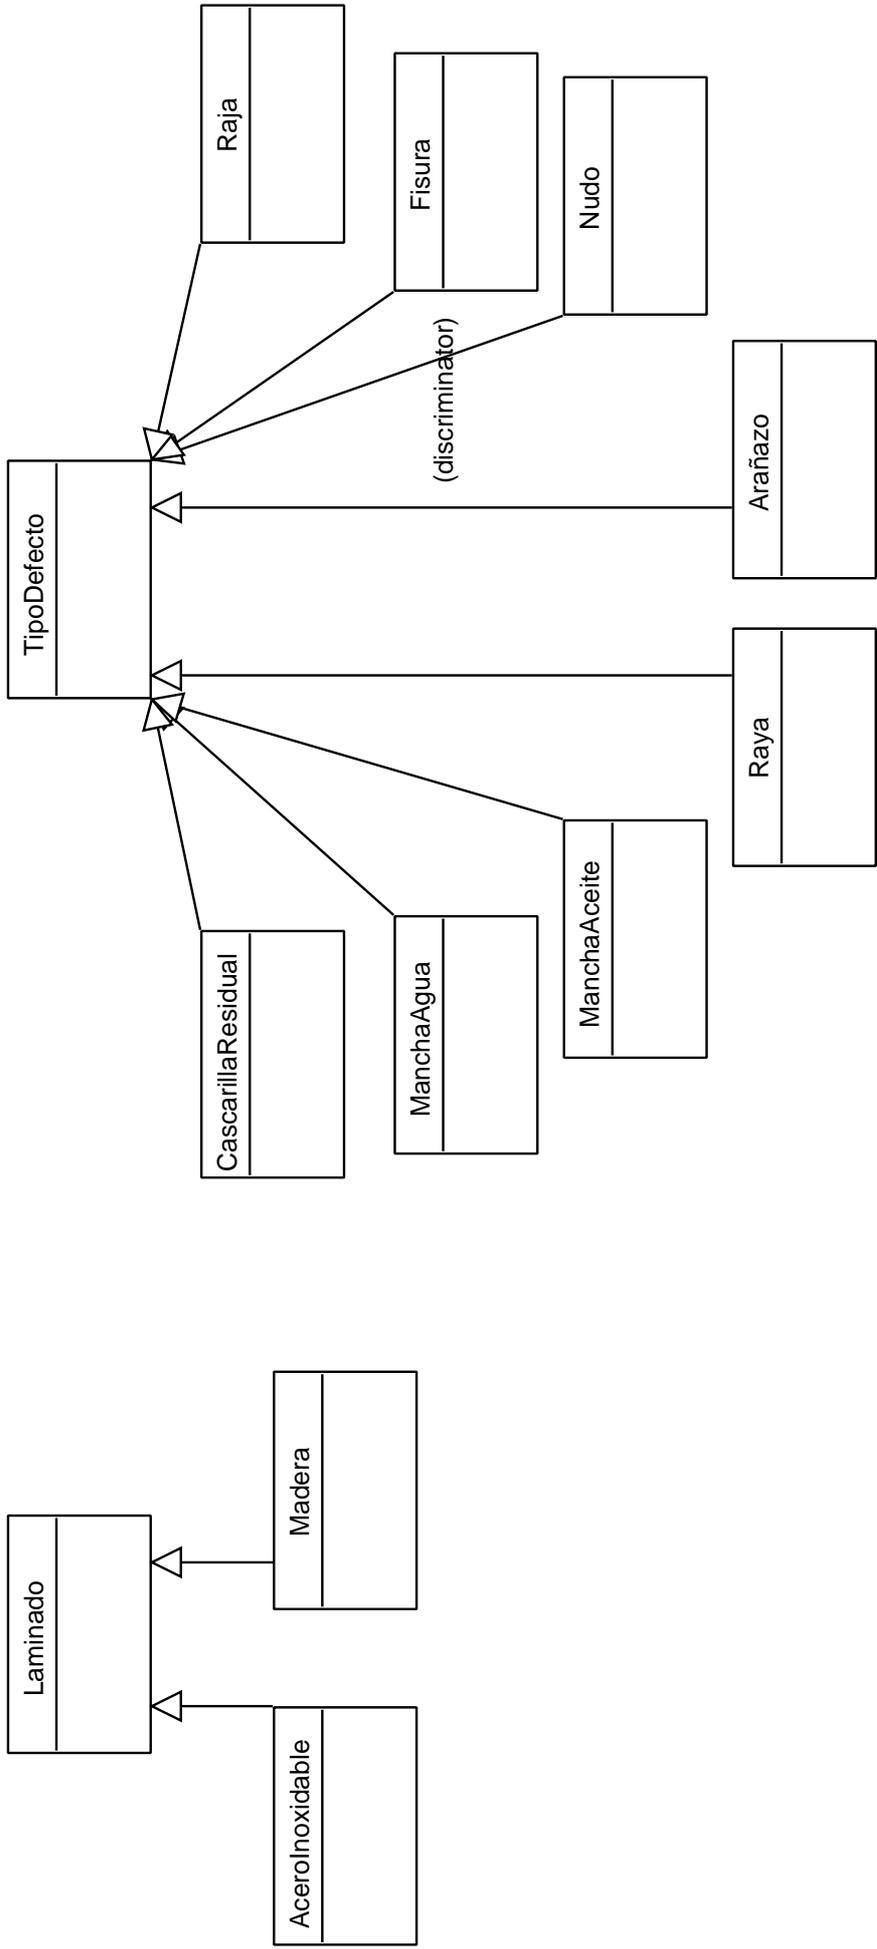
TipoDeDatosReglaCausal



06DC\_EspecificacionesRequisitos\_PreferenciasRestricciones\_DominioDeLaAplicación









# Apéndice D

## Estructura de control en la arquitectura ARDIS

Estructura de control de la tarea *Diseño-Configuración de Inspección de Superficies*:

Estructura de control de la subtarea *Configurar Esqueleto Inicial*:

Estructura de control de la subtarea *Proponer extensión esqueleto inicial*:

Estructura de control de la subtarea *Proponer extensión esqueleto entorno*:

Estructura de control de la subtarea *Proponer extensión esqueleto tiempo-real*:

Estructura de control de la subtarea *Proponer extensión esqueleto diagnóstico calidad*:

Estructura de control de la subtarea *Proponer extensión esqueleto técnicas visión artificial*:

Estructura de control de la subtarea *Clasificar/seleccionar Técnica Segmentación*:

Estructura de control de la subtarea *Clasificar/seleccionar Representador*:

---

TAREA Diseño-Configuración de Inspección de Superficies;

ROLES:

ENTRADA: Requisitos\_sistema\_de\_inspección\_de\_superficies;

SALIDA: Configuración\_global\_del\_sistema\_de\_Inspección\_de\_Superficies;

FIN TAREA Diseño-Configuración de Inspección de Superficies;

MÉTODO-TAREA proponer-y-revisar;

REALIZA: Diseño-Configuración de Inspección de Superficies;

DESCOMPOSICIÓN:

SUBTAREAS: Configurar esqueleto inicial, Proponer sistema,

Proveer Preferencias Globales y Restricciones Globales;

INFERENCIAS: Verificar sistema, Proponer reparaciones sistema

Seleccionar reparaciones sistema, Modificar sistema;

ROLES:

DINÁMICOS:

Requisitos\_sistema\_de\_inspección\_de\_superficies,

Esqueleto\_inicial\_del\_sistema,

Preferencias\_globales\_sistema\_de\_inspección,

Restricciones\_globales\_sistema\_de\_inspección,

Extensión\_esqueleto\_sistema\_actual,

Configuración\_global\_del\_sistema\_de\_Inspección\_de\_Superficies,

Imagen\_interpretada,

Sistema\_global\_óptimo,

Incumplimiento\_global\_de\_restricciones,

Lista\_global\_de\_reparaciones,

Reparación\_global;

ESTÁTICOS:

Reglas\_NBy/oB\_para\_Configurar\_Esqueleto\_Inicial,

Reglas\_NBy/oB\_para\_proveer\_PreferenciasGlobales-y-RestriccionesGlobales,

Reglas\_NBy/oB\_para\_componer\_esqueleto\_actual,

Reglas\_NBy/oB\_para\_verificar\_sistema,

Reglas\_NBy/oB\_para\_proponer\_reparaciones\_globales\_en\_función\_de\_la\_restricción,

Reglas\_NBy/oB\_para\_seleccionar\_reparaciones\_sistema,

Reglas\_NBy/oB\_para\_modificar\_sistema;

ESTRUCTURA DE CONTROL: (ver siguiente tabla D.2)

---

**Tabla D.1:** Estructura de control: secuencia de ejecución de las subtareas e inferencias de la tarea Diseño-Configuración de Inspección de Superficies (continua en la siguiente tabla D.2)

---

 ESTRUCTURA DE CONTROL:

```

Proveer Preferencias Globales y Restricciones Globales
  (Requisitos_sistema_de_inspección_de_superficies ->
  Preferencias_globales_sistema_de_inspección +
  Restricciones_globales_sistema_de_inspección)
Configurar esqueleto inicial (Requisitos_sistema_de_inspección_de_superficies ->
  Esqueleto_inicial_del_sistema)
MIENTRAS SOLUCIÓN-NUEVA Proponer sistema
  (Esqueleto_inicial_del_sistema +
  Requisitos_sistema_de_inspección_de_superficies +
  Preferencias_globales_sistema_de_inspección ->
  Extensión_esqueleto_sistema_actual) HACER
  Configuración_global_del_sistema_de_Inspección_de_Superficies :=
    Extensión_esqueleto_sistema_actual
  AÑADIR Configuración_global_del_sistema_de_Inspección_de_Superficies;
  Verificar sistema (Configuración_global_del_sistema_de_Inspección_de_Superficies
  + Restricciones_globales_sistema_de_inspección +
  Imagen_interpretada ->
  Sistema_global_óptimo + Incumplimiento_global_de_restricciones)
  SI Sistema_global_óptimo == falso
  ENTONCES
  Proponer reparaciones sistema (Incumplimiento_global_de_restricciones +
  Configuración_global_del_sistema_de_Inspección_de_Superficies ->
  Lista_global_de_reparaciones);
  REPETIR
  Seleccionar reparaciones sistema (Lista_global_de_reparaciones ->
  Reparación_global);
  Modificar sistema (Reparación_global +
  Configuración_global_del_sistema_de_Inspección_de_Superficies ->
  Configuración_global_del_sistema_de_Inspección_de_Superficies);
  Verificar sistema
  (Configuración_global_del_sistema_de_Inspección_de_Superficies +
  Restricciones_globales_sistema_de_inspección +
  Imagen_interpretada ->
  Sistema_global_óptimo + Incumplimiento_global_de_restricciones);
  HASTA Sistema_global_óptimo == verdadero;
  FIN REPETIR
  FIN SI
  FIN MIENTRAS
  FIN MÉTODO-TAREA proponer-y-revisar;

```

---

**Tabla D.2:** Continuación de la tabla D.1

---

SUBTAREA Configurar Esqueleto Inicial;

ROLES:

ENTRADA: Requisitos\_sistema\_de\_inspección\_de\_superficies;

SALIDA: Esqueleto\_inicial\_del\_sistema;

FIN SUBTAREA Configurar Esqueleto Inicial;

MÉTODO-SUBTAREA proponer-y-revisar;

REALIZA: Configurar Esqueleto Inicial;

DESCOMPOSICIÓN:

SUBTAREAS: Proveer preferencias restricciones esqueleto inicial;

INFERENCIAS: Especificar esqueleto inicial, Proponer esqueleto inicial,

Verificar esqueleto inicial, Proponer reparaciones esqueleto inicial,

Seleccionar reparaciones esqueleto inicial, Modificar esqueleto inicial;

ROLES:

DINÁMICOS:

Requisitos\_sistema\_de\_inspección\_de\_superficies,

Esqueleto\_basico\_inicial,

Preferencias\_esqueleto\_inicial,

Restricciones\_esqueleto\_inicial,

Extensión\_esqueleto\_inicial,

Esqueleto\_inicial\_del\_sistema,

Esqueleto\_inicial\_optimo,

Incumplimiento\_inicial\_de\_restricciones,

Lista\_inicial\_de\_reparaciones,

Reparación\_inicial;

ESTÁTICOS:

Reglas\_NBy/oB\_para\_Configurar\_Esqueleto\_Inicial,

Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_esqueleto\_inicial,

Reglas\_NBy/oB\_para\_proponer\_esqueleto\_inicial,

Reglas\_NBy/oB\_para\_verificar\_esqueleto\_inicial,

Reglas\_NBy/oB\_para\_proponer\_reparaciones\_esqueleto\_inicial\_en\_función\_de\_la\_restricción,

Reglas\_NBy/oB\_para\_seleccionar\_reparaciones\_esqueleto\_inicial,

Reglas\_NBy/oB\_para\_modificar\_esqueleto\_inicial;

ESTRUCTURA DE CONTROL: (ver siguiente tabla D.4)

---

**Tabla D.3:** Estructura de control: secuencia de ejecución de las subtarear e inferencias de la subtarea Configurar Esqueleto Inicial (continua en la siguiente tabla D.4)

## ESTRUCTURA DE CONTROL:

```

Proveer preferencias restricciones esqueleto inicial
  (Requisitos_sistema_de_inspección_de_superficies ->
  Preferencias_esqueleto_inicial +
  Restricciones_esqueleto_inicial)
Especificar esqueleto inicial (Requisitos_sistema_de_inspección_de_superficies ->
  Esqueleto_basico_inicial)
MIENTRAS SOLUCIÓN-NUEVA Proponer esqueleto inicial
  (Esqueleto_basico_inicial +
  Preferencias_esqueleto_inicial ->
  Extensión_esqueleto_inicial) HACER
  Esqueleto_inicial_del_sistema :=
    Extensión_esqueleto_inicial
    AÑADIR Esqueleto_inicial_del_sistema;
  Verificar esqueleto inicial (Esqueleto_inicial_del_sistema +
    Restricciones_esqueleto_inicial ->
    Esqueleto_inicial_optimo + Incumplimiento_inicial_de_restricciones)
  SI Esqueleto_inicial_optimo == falso
  ENTONCES
  Proponer reparaciones esqueleto inicial
  (Incumplimiento_inicial_de_restricciones +
    Esqueleto_inicial_del_sistema ->
    Lista_inicial_de_reparaciones);
  REPETIR
  Seleccionar reparaciones esqueleto inicial (Lista_inicial_de_reparaciones ->
    Reparación_inicial);
  Modificar esqueleto inicial (Reparación_inicial +
    Esqueleto_inicial_del_sistema ->
    Esqueleto_inicial_del_sistema);
  Verificar esqueleto inicial
  (Esqueleto_inicial_del_sistema +
  Restricciones_esqueleto_inicial ->
  Esqueleto_inicial_optimo + Incumplimiento_inicial_de_restricciones);
  HASTA Esqueleto_inicial_optimo == verdadero;
  FIN REPETIR
  FIN SI
  FIN MIENTRAS
FIN MÉTODO-SUBTAREA proponer-y-revisar;

```

---

**Tabla D.4:** Continuación de la tabla D.3

---

SUBTAREA Proponer extensión esqueleto inicial;

ROLES:

ENTRADA: Requisitos\_sistema\_de\_inspección\_de\_superficies,  
Preferencias\_globales\_sistema\_de\_inspección, Esqueleto\_inicial\_del\_sistema;

SALIDA: Extensión\_esqueleto\_sistema\_actual;

FIN SUBTAREA Proponer extensión esqueleto inicial;

MÉTODO-SUBTAREA descomponer-configuración-en-etapas;

REALIZA: Proponer extensión esqueleto inicial;

DESCOMPOSICIÓN:

SUBTAREAS: Proponer extensión esqueleto entorno,  
Proponer extensión esqueleto tiempo-real,  
Proponer extensión esqueleto diagnostico calidad,  
Proponer extensión esqueleto técnicas visión artificial;

INFERENCIAS: Componer esqueleto actual;

ROLES:

DINÁMICOS:

Requisitos\_sistema\_de\_inspección\_de\_superficies,  
Esqueleto\_inicial\_del\_sistema,  
Extensión\_esqueleto\_sistema(entorno),  
Extensión\_esqueleto\_sistema(tiempo-real),  
Extensión\_esqueleto\_sistema(calidad),  
Extensión\_esqueleto\_sistema(técnicas\_visión),  
Preferencias\_globales\_sistema\_de\_inspección,  
Extensión\_esqueleto\_sistema\_actual;

ESTÁTICOS:

Reglas\_NBy/oB\_para\_especificar\_entorno (Modelo causal),  
Reglas\_NBy/oB\_para\_especificar\_tiempo-real (Modelo causal),  
Reglas\_NBy/oB\_para\_diferenciar\_diagnostico\_calidad (Modelo causal),  
Reglas\_NBy/oB\_para\_diferenciar\_técnicas\_visión (Modelo causal),  
Reglas\_NBy/oB\_para\_componer\_esqueleto\_actual;

ESTRUCTURA DE CONTROL: (ver siguiente tabla D.6)

---

**Tabla D.5:** Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtask Proponer extensión esqueleto inicial (continua en la siguiente tabla D.6)

---

 ESTRUCTURA DE CONTROL:

```

Proponer extensión esqueleto entorno
  (Requisitos_sistema_de_inspección_de_superficies +
  Esqueleto_inicial_del_sistema ->
  Extensión_esqueleto_sistema(entorno))

Proponer extensión esqueleto tiempo-real
  (Requisitos_sistema_de_inspección_de_superficies +
  Esqueleto_inicial_del_sistema
  + Extensión_esqueleto_sistema(entorno) ->
  Extensión_esqueleto_sistema(tiempo-real))

Proponer extensión esqueleto diagnostico calidad
  (Requisitos_sistema_de_inspección_de_superficies +
  Esqueleto_inicial_del_sistema ->
  Extensión_esqueleto_sistema(calidad))

Proponer extensión esqueleto técnicas visión artificial
  (Requisitos_sistema_de_inspección_de_superficies +
  Esqueleto_inicial_del_sistema +
  Extensión_esqueleto_sistema(entorno)
  + Extensión_esqueleto_sistema(tiempo-real) +
  Extensión_esqueleto_sistema(calidad) ->
  Extensión_esqueleto_sistema(técnicas_visión))

SI SOLUCIÓN-NUEVA Componer esqueleto actual
  (Extensión_esqueleto_sistema(entorno) +
  Extensión_esqueleto_sistema(tiempo-real) +
  Extensión_esqueleto_sistema(calidad) +
  Extensión_esqueleto_sistema(técnicas_visión) +
  Preferencias_globales_sistema_de_inspección ->
  Extensión_esqueleto_sistema_actual) HACER
  Extensión_esqueleto_sistema_actual := Extensión_esqueleto_sistema_actual
  AÑADIR Extensión_esqueleto_sistema(entorno);
  Extensión_esqueleto_sistema_actual := Extensión_esqueleto_sistema_actual
  AÑADIR Extensión_esqueleto_sistema(tiempo-real);
  Extensión_esqueleto_sistema_actual := Extensión_esqueleto_sistema_actual
  AÑADIR Extensión_esqueleto_sistema(calidad);
  Extensión_esqueleto_sistema_actual := Extensión_esqueleto_sistema_actual
  AÑADIR Extensión_esqueleto_sistema(técnicas_visión);

FIN SI
FIN MÉTODO-SUBTAREA descomponer-configuración-en-etapas;

```

---

**Tabla D.6:** Continuación de la tabla D.5

---

SUBTAREA Proponer extensión esqueleto entorno;

ROLES:

ENTRADA: Requisitos \_sistema \_de \_inspección \_de \_superficies,  
Esqueleto \_inicial \_del \_sistema;

SALIDA: Extensión \_esqueleto \_sistema(entorno);

FIN SUBTAREA Proponer extensión esqueleto entorno;

MÉTODO-SUBTAREA proponer-y-revisar;

REALIZA: Proponer extensión esqueleto entorno;

DESCOMPOSICIÓN:

SUBTAREAS: Proveer preferencias restricciones entorno;

INFERENCIAS: Especificar entorno, Proponer entorno,  
Verificar entorno, Proponer reparaciones entorno,  
Seleccionar reparaciones entorno, Modificar entorno;

ROLES:

DINÁMICOS:

Requisitos \_sistema \_de \_inspección \_de \_superficies,  
Esqueleto \_inicial \_del \_sistema,  
Preferencias \_entorno,  
Restricciones \_entorno,  
Esqueleto \_entorno,  
Extensión \_entorno,  
Extensión \_esqueleto \_sistema(entorno),  
Entorno \_optimo,  
Incumplimiento \_restricciones \_entorno,  
Lista \_reparaciones \_entorno,  
Reparación \_entorno;

ESTÁTICOS:

Reglas \_NBy/oB \_para \_especificar \_entorno (Modelo causal),  
Reglas \_NBy/oB \_para \_proveer \_preferencias \_restricciones \_entorno,  
Reglas \_NBy/oB \_para \_proponer \_entorno,  
Reglas \_NBy/oB \_para \_verificar \_entorno,  
Reglas \_NBy/oB \_para \_proponer \_reparaciones \_entorno \_en \_función \_de \_la \_restricción,  
Reglas \_NBy/oB \_para \_seleccionar \_reparaciones \_entorno,  
Reglas \_NBy/oB \_para \_modificar \_entorno;

ESTRUCTURA DE CONTROL: (ver siguiente tabla D.8)

---

**Tabla D.7:** Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtask Proponer extensión esqueleto entorno (continúa en la siguiente tabla D.8)

## ESTRUCTURA DE CONTROL:

```

Proveer preferencias restricciones entorno
  (Requisitos_sistema_de_inspección_de_superficies ->
  Preferencias_entorno +
  Restricciones_entorno)
Especificar entorno (Requisitos_sistema_de_inspección_de_superficies +
  Esqueleto_inicial_del_sistema ->
  Esqueleto_entorno)
MIENTRAS SOLUCIÓN-NUEVA Proponer entorno
  (Esqueleto_entorno +
  Preferencias_entorno ->
  Extensión_entorno) HACER
  Extensión_esqueleto_sistema(entorno) :=
    Extensión_entorno
    AÑADIR Extensión_esqueleto_sistema(entorno);
  Verificar entorno (Extensión_esqueleto_sistema(entorno) +
    Restricciones_entorno ->
    Entorno_optimo + Incumplimiento_restricciones_entorno)
  SI Entorno_optimo == falso
  ENTONCES
  Proponer reparaciones entorno
  (Incumplimiento_restricciones_entorno +
    Extensión_esqueleto_sistema(entorno) ->
    Lista_reparaciones_entorno);
  REPETIR
  Seleccionar reparaciones entorno (Lista_reparaciones_entorno ->
    Reparación_entorno);
  Modificar entorno (Reparación_entorno +
    Extensión_esqueleto_sistema(entorno) ->
    Extensión_esqueleto_sistema(entorno));
  Verificar entorno
  (Extensión_esqueleto_sistema(entorno) +
  Restricciones_entorno ->
  Entorno_optimo + Incumplimiento_restricciones_entorno);
  HASTA Entorno_optimo == verdadero;
  FIN REPETIR
  FIN SI
  FIN MIENTRAS
FIN MÉTODO-SUBTAREA proponer-y-revisar;

```

---

**Tabla D.8:** Continuación de la tabla D.7

---

SUBTAREA Proponer extensión esqueleto tiempo-real;

ROLES:

ENTRADA: Requisitos\_sistema\_de\_inspección\_de\_superficies,  
Esqueleto\_inicial\_del\_sistema,  
Extensión\_esqueleto\_sistema(entorno);

SALIDA: Extensión\_esqueleto\_sistema(tiempo-real);

FIN SUBTAREA Proponer extensión esqueleto tiempo-real;

MÉTODO-SUBTAREA proponer-y-revisar;

REALIZA: Proponer extensión esqueleto tiempo-real;

DESCOMPOSICIÓN:

SUBTAREAS: Proveer preferencias restricciones tiempo\_real;

INFERENCIAS: Especificar tiempo\_real, Proponer tiempo\_real,  
Verificar tiempo\_real, Proponer reparaciones tiempo\_real,  
Seleccionar reparaciones tiempo\_real, Modificar tiempo\_real;

ROLES:

DINÁMICOS:

Requisitos\_sistema\_de\_inspección\_de\_superficies,  
Esqueleto\_inicial\_del\_sistema,  
Extensión\_esqueleto\_sistema(entorno),  
Preferencias\_tiempo\_real,  
Restricciones\_tiempo\_real,  
Esqueleto\_tiempo\_real,  
Extensión\_tiempo\_real,  
Extensión\_esqueleto\_sistema(tiempo-real),  
Tiempo\_real\_optimo,  
Incumplimiento\_restricciones\_tiempo\_real,  
Lista\_reparaciones\_tiempo\_real,  
Reparación\_tiempo\_real;

ESTÁTICOS:

Reglas\_NBy/oB\_para\_especificar\_tiempo-real (Modelo causal),  
Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_tiempo-real,  
Reglas\_NBy/oB\_para\_proponer\_tiempo\_real,  
Reglas\_NBy/oB\_para\_verificar\_tiempo\_real,  
Reglas\_NBy/oB\_para\_proponer\_reparaciones\_tiempo\_real\_en\_función\_de\_la\_restricción,  
Reglas\_NBy/oB\_para\_seleccionar\_reparaciones\_tiempo\_real,  
Reglas\_NBy/oB\_para\_modificar\_tiempo\_real;

ESTRUCTURA DE CONTROL: (ver siguiente tabla D.10)

---

**Tabla D.9:** Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Proponer extensión esqueleto tiempo-real (continua en la siguiente tabla D.10)

## ESTRUCTURA DE CONTROL:

```

Proveer preferencias restricciones tiempo_real
  (Requisitos_sistema_de_inspección_de_superficies +
  Extensión_esqueleto_sistema(entorno) ->
  Preferencias_tiempo_real +
  Restricciones_tiempo_real)
Especificar tiempo_real (Requisitos_sistema_de_inspección_de_superficies +
  Esqueleto_inicial_del_sistema +
  Extensión_esqueleto_sistema(entorno) ->
  Esqueleto_tiempo_real)
MIENTRAS SOLUCIÓN-NUEVA Proponer tiempo_real
  (Esqueleto_tiempo_real +
  Preferencias_tiempo_real ->
  Extensión_tiempo_real) HACER
  Extensión_esqueleto_sistema(tiempo-real) :=
    Extensión_tiempo_real
    AÑADIR Extensión_esqueleto_sistema(tiempo-real);
  Verificar tiempo_real (Extensión_esqueleto_sistema(tiempo-real) +
    Restricciones_tiempo_real ->
    Tiempo_real_optimo + Incumplimiento_restricciones_tiempo_real)
  SI Tiempo_real_optimo == falso
  ENTONCES
  Proponer reparaciones tiempo_real
  (Incumplimiento_restricciones_tiempo_real +
    Extensión_esqueleto_sistema(tiempo-real) ->
    Lista_reparaciones_tiempo_real);
  REPETIR
  Seleccionar reparaciones tiempo_real (Lista_reparaciones_tiempo_real ->
    Reparación_tiempo_real);
  Modificar tiempo_real (Reparación_tiempo_real +
    Extensión_esqueleto_sistema(tiempo-real) ->
    Extensión_esqueleto_sistema(tiempo-real));
  Verificar tiempo_real
  (Extensión_esqueleto_sistema(tiempo-real) +
    Restricciones_tiempo_real ->
    Tiempo_real_optimo + Incumplimiento_restricciones_tiempo_real);
  HASTA Tiempo_real_optimo == verdadero;
  FIN REPETIR
  FIN SI
  FIN MIENTRAS
FIN MÉTODO-SUBTAREA proponer-y-revisar;

```

Tabla D.10: Continuación de la tabla D.9

---

SUBTAREA Proponer extensión esqueleto diagnostico calidad;

ROLES:

ENTRADA: Requisitos\_sistema\_de\_inspección\_de\_superficies,  
Esqueleto\_inicial\_del\_sistema;

SALIDA: Extensión\_esqueleto\_sistema(calidad);

FIN SUBTAREA Proponer extensión esqueleto diagnostico calidad;

MÉTODO-SUBTAREA cubrir-y-diferenciar;

REALIZA: Proponer extensión esqueleto diagnostico calidad;

DESCOMPOSICIÓN:

SUBTAREAS: Proveer Preferencias y Restricciones control calidad;

INFERENCIAS: Cubrir diagnostico calidad, Diferenciar diagnostico calidad;

ROLES:

DINÁMICOS:

Requisitos\_sistema\_de\_inspección\_de\_superficies,  
Preferencias\_control\_calidad,  
Restricciones\_control\_calidad,  
Hipótesis\_métodos\_de\_control\_de\_calidad,  
Esqueleto\_inicial\_del\_sistema,  
Extensión\_esqueleto\_sistema(calidad);

ESTÁTICOS:

Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_calidad,  
Reglas\_NBy/oB\_para\_selección\_de\_métodos\_de\_control\_de\_calidad,  
Reglas\_NBy/oB\_para\_diferenciar\_diagnostico\_calidad (Modelo causal);

ESTRUCTURA DE CONTROL:

Proveer Preferencias y Restricciones control calidad

(Requisitos\_sistema\_de\_inspección\_de\_superficies ->  
Preferencias\_control\_calidad + Restricciones\_control\_calidad)

MIENTRAS EXISTA-RESTRICCIÓN Cubrir diagnostico calidad

(Restricciones\_control\_calidad ->  
Hipótesis\_métodos\_de\_control\_de\_calidad) HACER

SI EXISTE-HIPÓTESIS == verdadero

REPETIR

Diferenciar diagnostico calidad (Esqueleto\_inicial\_del\_sistema +  
Hipótesis\_métodos\_de\_control\_de\_calidad +  
Preferencias\_control\_calidad ->  
Extensión\_esqueleto\_sistema(calidad));

HASTA EXISTE-HIPÓTESIS == falso;

FIN REPETIR

FIN MIENTRAS

FIN MÉTODO-SUBTAREA cubrir-y-diferenciar;

---

**Tabla D.11:** Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtask Proponer extensión esqueleto diagnostico calidad

---

SUBTAREA Proponer extensión esqueleto técnicas visión artificial;

ROLES:

ENTRADA: Requisitos\_sistema\_de\_inspección\_de\_superficies,  
 Esqueleto\_inicial\_del\_sistema, Extensión\_esqueleto\_sistema(entorno),  
 Extensión\_esqueleto\_sistema(tiempo-real), Extensión\_esqueleto\_sistema(calidad);  
 SALIDA: Extensión\_esqueleto\_sistema(técnicas\_visión);

FIN SUBTAREA Proponer extensión esqueleto técnicas visión artificial;

MÉTODO-SUBTAREA descomponer-técnicas-visión-en-etapas;

REALIZA: Proponer extensión esqueleto técnicas visión artificial;

DESCOMPOSICIÓN:

SUBTAREAS: Proveer preferencias restricciones segmentación, Clasificar/seleccionar técnica segmentación,  
 Proveer preferencias restricciones representación, Clasificar/seleccionar representador,  
 Proveer preferencias restricciones descripción, Clasificar/seleccionar descriptor,  
 Proveer preferencias restricciones reconocimiento, Clasificar/seleccionar reconocedor,  
 Proveer preferencias restricciones interpretación, Clasificar/seleccionar interpretador;

INFERENCIAS: Seleccionar Preprocesado, Aplicar técnica de segmentación,  
 Aplicar técnica de representación, Aplicar técnica de descripción,  
 Aplicar técnica de reconocimiento, Aplicar técnica de interpretación, Componer técnicas visión;

ROLES:

DINÁMICOS:

Requisitos\_sistema\_de\_inspección\_de\_superficies, Esqueleto\_inicial\_del\_sistema,  
 Imagen\_RGB, Canal\_imagen\_RGB, Extensión\_esqueleto\_sistema(técnicas\_visión),  
 Preferencias\_segmentación, Restricciones\_segmentación, Técnica\_de\_segmentación\_de\_la\_superficie,  
 Preferencias\_representación, Restricciones\_representación, Técnica\_de\_representación\_de\_la\_superficie,  
 Preferencias\_descripción, RestriccionesDescripción, Técnica\_de\_descripción\_de\_la\_superficie,  
 Preferencias\_reconocimiento, RestriccionesReconocimiento, Técnica\_de\_clasificación\_de\_la\_superficie,  
 Preferencias\_interpretación, RestriccionesInterpretación, Técnica\_de\_interpretación\_de\_la\_superficie,  
 Imagen\_segmentada, Imagen\_representada, Imagen\_descrita, Imagen\_clasificada, Imagen\_interpretada

ESTÁTICOS:

Reglas\_NBy/oB\_para\_seleccionar\_preprocesado, Reglas\_NBy/oB\_para\_componer\_técnicas\_visión,  
 Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_segmentación,  
 Reglas\_NBy/oB\_para\_selección\_de\_técnicas\_de\_segmentación,  
 Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_representación,  
 Reglas\_NBy/oB\_para\_selección\_de\_técnicas\_de\_representación,  
 Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_descripción,  
 Reglas\_NBy/oB\_para\_selección\_de\_técnicas\_de\_descripción,  
 Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_reconocimiento,  
 Reglas\_NBy/oB\_para\_selección\_de\_técnicas\_de\_reconocimiento,  
 Reglas\_NBy/oB\_para\_proveer\_preferencias\_restricciones\_interpretación,  
 Reglas\_NBy/oB\_para\_selección\_de\_técnicas\_de\_interpretación,

ESTRUCTURA DE CONTROL: (ver siguiente tabla D.13)

---

**Tabla D.12:** Estructura de control: secuencia de ejecución de las subtareas e inferencias de la subtarea Proponer extensión esqueleto técnicas visión artificial (continua en la siguiente tabla D.13)

## ESTRUCTURA DE CONTROL:

Seleccionar Preprocesado

(Requisitos\_sistema\_de\_inspección\_de\_superficies + Imagen\_RGB -> Canal\_imagen\_RGB)

Proveer preferencias restricciones segmentación

(Requisitos\_sistema\_de\_inspección\_de\_superficies -> Preferencias\_segmentación + Restricciones\_segmentación)

Clasificar/seleccionar técnica segmentación

(Canal\_imagen\_RGB + Preferencias\_segmentación +  
Restricciones\_segmentación -> Técnica\_de\_segmentación\_de\_la\_superficie)

Aplicar técnica de segmentación

(Canal\_imagen\_RGB + Técnica\_de\_segmentación\_de\_la\_superficie -> Imagen\_segmentada)

Proveer preferencias restricciones representación

(Requisitos\_sistema\_de\_inspección\_de\_superficies -> Preferencias\_representación + Restricciones\_representación)

Clasificar/seleccionar representador

(Técnica\_de\_segmentación\_de\_la\_superficie + Preferencias\_representación + Restricciones\_representación +  
Imagen\_segmentada -> Técnica\_de\_representación\_de\_la\_superficie)

Aplicar técnica de representación

(Imagen\_segmentada + Técnica\_de\_representación\_de\_la\_superficie -> Imagen\_representada)

Proveer preferencias restricciones descripción

(Requisitos\_sistema\_de\_inspección\_de\_superficies -> Preferencias\_descripción + Restricciones\_Descripción)

Clasificar/seleccionar descriptor

(Técnica\_de\_representación\_de\_la\_superficie + Técnica\_de\_segmentación\_de\_la\_superficie +  
Preferencias\_descripción + Restricciones\_Descripción + Imagen\_segmentada  
Imagen\_representada -> Técnica\_de\_descripción\_de\_la\_superficie)

Aplicar técnica de descripción

(Imagen\_segmentada + Imagen\_representada + Técnica\_de\_descripción\_de\_la\_superficie -> Imagen\_descrita)

Proveer preferencias restricciones reconocimiento

(Requisitos\_sistema\_de\_inspección\_de\_superficies -> Preferencias\_reconocimiento + Restricciones\_Reconocimiento)

Clasificar/seleccionar reconocedor

(Técnica\_de\_descripción\_de\_la\_superficie + Preferencias\_reconocimiento + Restricciones\_Reconocimiento  
Imagen\_descrita -> Técnica\_de\_clasificación\_de\_la\_superficie)

Aplicar técnica de reconocimiento

(Imagen\_descrita + Técnica\_de\_clasificación\_de\_la\_superficie -> Imagen\_clasificada)

Proveer preferencias restricciones interpretación

(Requisitos\_sistema\_de\_inspección\_de\_superficies -> Preferencias\_interpretación + Restricciones\_Interpretación)

Clasificar/seleccionar interpretador

(Técnica\_de\_clasificación\_de\_la\_superficie + Preferencias\_interpretación + Restricciones\_Interpretación  
Imagen\_clasificada -> Técnica\_de\_interpretación\_de\_la\_superficie)

Aplicar técnica de interpretación

(Imagen\_clasificada + Técnica\_de\_interpretación\_de\_la\_superficie -> Imagen\_interpretada)

**Tabla D.13:** Continuación de la tabla D.12

---

SI SOLUCIÓN-NUEVA Componer\_técnicas\_visión

(Técnica\_de\_segmentación\_de\_la\_superficie + Técnica\_de\_representación\_de\_la\_superficie +  
Técnica\_de\_descripción\_de\_la\_superficie + Técnica\_de\_clasificación\_de\_la\_superficie  
Técnica\_de\_interpretación\_de\_la\_superficie -> Extensión\_esqueleto\_sistema(técnicas\_visión)) HACER

Extensión\_esqueleto\_sistema(técnicas\_visión) := Extensión\_esqueleto\_sistema(técnicas\_visión)

AÑADIR Técnica\_de\_segmentación\_de\_la\_superficie;

Extensión\_esqueleto\_sistema(técnicas\_visión) := Extensión\_esqueleto\_sistema(técnicas\_visión)

AÑADIR Técnica\_de\_representación\_de\_la\_superficie;

Extensión\_esqueleto\_sistema(técnicas\_visión) := Extensión\_esqueleto\_sistema(técnicas\_visión)

AÑADIR Técnica\_de\_descripción\_de\_la\_superficie;

Extensión\_esqueleto\_sistema(técnicas\_visión) := Extensión\_esqueleto\_sistema(técnicas\_visión)

AÑADIR Técnica\_de\_clasificación\_de\_la\_superficie;

Extensión\_esqueleto\_sistema(técnicas\_visión) := Extensión\_esqueleto\_sistema(técnicas\_visión)

AÑADIR Técnica\_de\_interpretación\_de\_la\_superficie;

FIN SI

FIN MÉTODO-SUBTAREA descomponer-técnicas-visión-en-etapas;

---

**Tabla D.14:** Continuación de la tabla D.13

---

SUBTAREA Clasificar/seleccionar Técnica Segmentación;

ROLES:

ENTRADA: Canal\_imagen\_RGB, Restricciones\_segmentación, Preferencias\_segmentación  
Esqueleto\_inicial\_del\_sistema, Extensión\_esqueleto\_sistema(entorno)  
Extensión\_esqueleto\_sistema(tiempo-real), Extensión\_esqueleto\_sistema(calidad);

SALIDA: Técnica\_de\_segmentación\_de\_la\_superficie;

FIN SUBTAREA Clasificar/seleccionar Técnica Segmentación;

MÉTODO-SUBTAREA cubrir-y-diferenciar;

REALIZA: Clasificar/seleccionar Técnica Segmentación;

DESCOMPOSICIÓN:

INFERENCIAS: Cubrir técnica segmentación, Diferenciar técnica segmentación,  
Seleccionar observación para segmentación;

ROLES:

DINÁMICOS:

Canal\_imagen\_RGB, Restricciones\_segmentación, Preferencias\_segmentación  
Esqueleto\_inicial\_del\_sistema, Extensión\_esqueleto\_sistema(entorno)  
Extensión\_esqueleto\_sistema(tiempo-real), Extensión\_esqueleto\_sistema(calidad)  
Hipótesis\_métodos\_segmentación, Observaciones\_adicionales\_de\_la\_imagen  
Técnica\_de\_segmentación\_de\_la\_superficie;

ESTÁTICOS:

Reglas\_NBy/oB\_para\_selección\_de\_técnicas\_de\_segmentación,  
Reglas\_NBy/oB\_para\_diferenciar\_técnicas\_visión (Modelo causal),  
Reglas\_NBy/oB\_para\_seleccionar\_observación\_de\_segmentación;

ESTRUCTURA DE CONTROL:

Seleccionar observación para segmentación

(Canal\_imagen\_RGB -> Observaciones\_adicionales\_de\_la\_imagen)

MIENTRAS EXISTA-RESTRICCIÓN Cubrir técnica segmentación

(Canal\_imagen\_RGB + Restricciones\_segmentación ->

Hipótesis\_métodos\_segmentación) HACER

SI EXISTE-HIPÓTESIS == verdadero

REPETIR

Diferenciar técnica segmentación (Esqueleto\_inicial\_del\_sistema +

Preferencias\_segmentación + Hipótesis\_métodos\_segmentación +

Observaciones\_adicionales\_de\_la\_imagen + Extensión\_esqueleto\_sistema(entorno),

+ Extensión\_esqueleto\_sistema(tiempo-real) + Extensión\_esqueleto\_sistema(calidad)

-> Técnica\_de\_segmentación\_de\_la\_superficie);

HASTA EXISTE-HIPÓTESIS == falso;

FIN REPETIR

FIN MIENTRAS

FIN MÉTODO-SUBTAREA cubrir-y-diferenciar;

---

**Tabla D.15:** Estructura de control: secuencia de ejecución de las inferencias de la subtarea  
Clasificar/seleccionar Técnica Segmentación

---

SUBTAREA Clasificar/seleccionar Representador;

ROLES:

ENTRADA: Técnica\_de\_segmentación\_de\_la\_superficie, Restricciones\_representación,  
 Imagen\_segmentada, Esqueleto\_inicial\_del\_sistema,  
 Preferencias\_representación, Extensión\_esqueleto\_sistema(entorno),  
 Extensión\_esqueleto\_sistema(tiempo-real), Extensión\_esqueleto\_sistema(calidad);

SALIDA: Técnica\_de\_representación\_de\_la\_superficie;

FIN SUBTAREA Clasificar/seleccionar Representador;

MÉTODO-SUBTAREA cubrir-y-diferenciar;

REALIZA: Clasificar/seleccionar Representador;

DESCOMPOSICIÓN:

INFERENCIAS: Cubrir técnica representación, Diferenciar técnica representación,  
 Seleccionar observación para representación;

ROLES:

DINÁMICOS:

Técnica\_de\_segmentación\_de\_la\_superficie, Restricciones\_representación,  
 Imagen\_segmentada, Esqueleto\_inicial\_del\_sistema, Preferencias\_representación,  
 Hipótesis\_métodos\_representación, Observaciones\_adicionales\_de\_la\_segmentación,  
 Extensión\_esqueleto\_sistema(entorno), Extensión\_esqueleto\_sistema(tiempo-real)  
 Extensión\_esqueleto\_sistema(calidad), Técnica\_de\_representación\_de\_la\_superficie;

ESTÁTICOS:

Reglas\_NBy/oB\_para\_selección\_de\_técnicas\_de\_representación,  
 Reglas\_NBy/oB\_para\_diferenciar\_técnicas\_visión (Modelo causal),  
 Reglas\_NBy/oB\_para\_seleccionar\_observación\_de\_representación;

ESTRUCTURA DE CONTROL:

Seleccionar observación para representación

(Imagen\_segmentada -> Observaciones\_adicionales\_de\_la\_segmentación)

MIENTRAS EXISTA-RESTRICCIÓN Cubrir técnica representación

(Técnica\_de\_segmentación\_de\_la\_superficie + Restricciones\_representación,  
 Imagen\_segmentada -> Hipótesis\_métodos\_representación) HACER

SI EXISTE-HIPÓTESIS == verdadero

REPETIR

Diferenciar técnica representación (Esqueleto\_inicial\_del\_sistema +  
 Preferencias\_representación + Hipótesis\_métodos\_representación +  
 Observaciones\_adicionales\_de\_la\_segmentación +  
 Extensión\_esqueleto\_sistema(entorno) +  
 Extensión\_esqueleto\_sistema(tiempo-real) + Extensión\_esqueleto\_sistema(calidad)  
 -> Técnica\_de\_representación\_de\_la\_superficie);

HASTA EXISTE-HIPÓTESIS == falso;

FIN REPETIR

FIN MIENTRAS

FIN MÉTODO-SUBTAREA cubrir-y-diferenciar;

---

**Tabla D.16:** Estructura de control: secuencia de ejecución de las inferencias de la subtaska Clasificar/seleccionar Representador



# Bibliografía

- [Acerinox, 2007] Acerinox, S. A. (2007). ACERINOX, S.A. (Factoría del Campo de Gibraltar, España). Fábrica integral de producto plano de acero inoxidable.
- [Achour & Mahiddine, 2002] Achour, K. & Mahiddine, L. (2002). Hopfield neural network based stereo matching algorithm. *Journal of Mathematical Imaging and Vision*, 16, 17–29.
- [Adameck et al., 2003] Adameck, M., Hossfeld, M., & Eich, M. (2003). Three color selective stereo gradient method for fast topography recognition of metallic surfaces. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection XI*, number 5011 (pp. 128–139). Santa Clara, California, USA.
- [AdvantechIndustrialComputer, 2007] AdvantechIndustrialComputer (2007). Advantech IPC-603MB Industrial Platform with Front-accessible I/O Cabling. Advantech.
- [Agarwal & Chaudhuri, 1998] Agarwal, S. & Chaudhuri, S. (1998). Determination of aircraft orientation for a vision-based system using artificial neural networks. *Journal of Mathematical Imaging and Vision*, 8, 255–269.
- [Albus & Barbera, 2005] Albus, J. S. & Barbera, A. J. (2005). Rcs: A cognitive architecture for intelligent multi-agent systems. *Annual Reviews in Control*, 29, 87–99.
- [Allgood et al., 2000] Allgood, G. O., Treece, D. A., Mee, D. K., & Mooney, L. R. (2000). Textile laser-optical system for inspecting fabric structure and form. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 270–279). San Jose, California.
- [Altamirano et al., 2000] Altamirano, L., Arias, M., Alviso, S., & López, A. (2000). Submillimeter bolt location in car bodywork for production line quality inspection. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 249–258). San Jose, California.
- [Anderson et al., 1997] Anderson, J. R., Matessa, M., & Lebiere, C. (1997). An overview of the epic architecture for cognition and performance with application to human-computer interaction. *Human-Computer Interaction*, 12, 391–438.

- [Arias-Estrada & Torres-Huitzil, 2000] Arias-Estrada, M. & Torres-Huitzil, C. (2000). Real-time fpga architectures for computer vision. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 30–39). San Jose, California.
- [Azar & Weston, 1988] Azar, I. & Weston, R. H. (1988). On vision architecture for computer integrated manufacturing. *Microprocessors and Microsystems*, 12, 24–32.
- [Babu & Ramakrishnan, 2004] Babu, R. V. & Ramakrishnan, K. R. (2004). Recognition of human actions using motion history information extracted from the compressed video. *Image and Vision Computing*, 22, 597–607.
- [Bahlmann et al., 1999] Bahlmann, C., Heidemann, G., & Ritter, H. (1999). Artificial neural networks for automated quality control of textile seams. *Pattern Recognition*, 32, 1049–1060.
- [Batchelor, 1998] Batchelor, B. G. (1998). Knowledge-based program to assist in the design of machine vision systems. In *Proceedings of SPIE Machine Vision Systems for Inspection and Metrology VII*, number 3521 (pp. 312–324). Boston, MA, USA.
- [Batchelor & Whelan, 1997] Batchelor, B. G. & Whelan, P. F. (1997). *Intelligent Vision Systems for Industry*. Springer-Verlag.
- [Bellas et al., 2006] Bellas, F., Faina, A., Prieto, A., & Duro, R. J. (2006). Adaptive learning application of the mdb evolutionary cognitive architecture in physical agents. In *From Animals to Animals 9. 9th International Conference on Simulation of Adaptive Behavior, SAB 2006. Proceedings Lecture Notes in Artificial Intelligence*, number 4095 (pp. 434–479). Rome, Italy.
- [Benitez, 2003] Benitez, D. (2003). Performance of reconfigurable architectures for image-processing applications. *Journal of Systems Architecture*, 49, 193–210.
- [Benjamin et al., 2006] Benjamin, D. P., Lyons, D., & Achtemichuk, T. (2006). Obstacle avoidance using predictive vision based on a dynamic 3d world model. In *Proceedings of SPIE Intelligent Robots and Computer Vision XXIV: Algorithms, Techniques, and Active Vision*, number 6384 Boston, MA, United States.
- [Bhandarkar et al., 1999] Bhandarkar, S. M., Faust, T. D., & Tang, M. (1999). Catalog: a system for detection and rendering of internal log defects using computer tomography. *Machine Vision and Applications*, 11, 171–190.
- [Bischof & Leonardis, 2001] Bischof, H. & Leonardis, A. (2001). View-based object representations using rbf networks. *Image and Vision Computing*, 19, 619–629.
- [Booch et al., 2005] Booch, G., Rumbaugh, J., & Jacobson, I. (2005). *The Unified Modeling Language User Guide*. Addison-Wesley, second edition edition.

- [Bourgeat et al., 2003] Bourgeat, P., Meriaudeau, F., Gorria, P., & Tobin, K. W. (2003). Content-based segmentation of patterned wafer for automatic threshold determination. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection XI*, number 5011 (pp. 183–189). Santa Clara, California, USA.
- [Boyer & Ozguner, 2001] Boyer, k. L. & Ozguner, T. (2001). Robust online detection of pipeline corrosion from range data. *Machine Vision and Applications*, 12, 291–304.
- [Burel & Carel, 1994] Burel, G. & Carel, D. (1994). Detection and localization of faces on digital images. *Pattern Recognition Letters*, 15, 963–967.
- [Cabello et al., 2002] Cabello, E., Sanchez, M. A., & Delgado, J. (2002). A new approach to identify big rocks with applications to the mining industry. *Real-Time Imaging*, 8, 1–9.
- [Campadelli et al., 1997] Campadelli, P., Medici, D., & Schettini, R. (1997). Color image segmentation using hopfield networks. *Image and Vision Computing*, 15, 161–166.
- [Carpenter et al., 1998] Carpenter, G. A., Grossberg, S., & Lesher, G. W. (1998). The wat-and-where filter. a spatial mapping neural network for object recognition and image understanding. *Computer Vision and Image Understanding*, 69, 1–22.
- [Casasent & Chen, 2003] Casasent, D. & Chen, X.-w. (2003). New training strategies for rbf neural networks for x-ray agricultural product inspection. *Pattern Recognition*, 36, 535–547.
- [Chai et al., 2001] Chai, M. I. B., Chai, A., & Sullivan, P. (2001). Boundary detection of retinoblastoma tumors with neural networks. *Computerized Medical Imaging and Graphics*, 25, 257–264.
- [Chang & Chung, 2001] Chang, C.-Y. & Chung, P.-C. (2001). Medical image segmentation using a contextual-constraint-based hopfield neural cube. *Image and Vision Computing*, 19, 669–678.
- [Chella et al., 1997] Chella, A., Frixione, M., & Gaglio, S. (1997). A cognitive architecture for artificial vision. *Artificial Intelligence*, 89, 73–111.
- [Chella et al., 2000] Chella, A., Frixione, M., & Gaglio, S. (2000). Understanding dynamic scenes. *Artificial Intelligence*, 123, 89–132.
- [Chiang & Gader, 1997] Chiang, J.-H. & Gader, P. D. (1997). Recognition of hand-printed numerals in visa card application forms. *Machine Vision and Applications*, 10, 144–149.
- [Chin, 1988] Chin, R. T. (1988). Survey automated visual inspection: 1981 to 1987. *Computer Vision, Graphics and Image Processing*, 41, 346–381.

- [Christoyianni et al., 2002] Christoyianni, I., Koutras, A., Dermatas, E., & Kokkinakis, G. (2002). Computer aided diagnosis of breast cancer in digitized mammograms. *Computerized Medical Imaging and Graphics*, 26, 309–319.
- [Chung & Kim, 1998] Chung, Y. K. & Kim, K. H. (1998). Automated visual inspection system of automobile doors and windows using the adaptive feature extraction. In *Proceedings KES'98. Second International Conference on Knowledge-Based Intelligent Electronic Systems*, number 3 (pp. 286–293).
- [Conci & Belmiro, 2002] Conci, A. & Belmiro, C. (2002). A system for real-time fabric inspection and industrial decision. In *SIKES'02* (pp. 707–714). Ischia, Italy.
- [Convertino et al., 1997] Convertino, G., Stella, E., Branca, A., & Distante, A. (1997). Optic flow estimation by a hopfield neural network using geometrical constrains. *Machine Vision and Applications*, 10, 114–122.
- [Coward, 2001] Coward, L. A. (2001). The recommendation architecture: lessons from large-scale electronic systems applied to cognition. *Journal of Cognitive Systems Research*, 2, 111–156.
- [Demant et al., 1999] Demant, C., Streicher-Abel, B., & Waszkewitz, P. (1999). *Industrial Image Processing. Visual Quality Control In Manufacturing*. Springer-Verlag.
- [Derganc et al., 2003] Derganc, J., Likar, B., Bernard, R., Tomazevic, D., & Pernus, F. (2003). Real-time automated visual inspection of color tablets in pharmaceutical blisters. *Real-Time Imaging*, 9, 113–124.
- [Douglass, 1998] Douglass, B. P. (1998). *Real-Time UML. Developing Efficient Objects for Embedded Systems*. Addison-Wesley.
- [Douville, 2000] Douville, P. (2000). Real-time classification of traffic signs. *Real-Time Imaging*, 6, 185–193.
- [Drake & Packianather, 1998] Drake, P. R. & Packianather, M. S. (1998). A decision tree of neural networks for classifying images of wood veneer. *International Journal of Advanced Manufacturing Technology*, 14, 280–285.
- [Eduardo, 1993a] Eduardo, B. C. (1993a). Review of automated visual inspection 1983 to 1993 – part i: conventional approaches. In *Proceedings of SPIE Intelligent Robots and Computer Vision XII*, number 2055 (pp. 128–158).
- [Eduardo, 1993b] Eduardo, B. C. (1993b). Review of automated visual inspection 1983 to 1993 – part ii: approaches to intelligent systems. In *Proceedings of SPIE Intelligent Robots and Computer Vision XII*, number 2055 (pp. 159–172).

- [Egmont-Petersen & Pelikan, 1999] Egmont-Petersen, M. & Pelikan, E. (1999). Detection of bone tumours in radiographic images using neural networks. *Pattern Analysis and Applications*, 2, 172–183.
- [Eriksson & Penker, 1998] Eriksson, H.-E. & Penker, M. (1998). *UML Toolkit*. John Wiley and Sons.
- [Fayman et al., 1998] Fayman, J. A., Rivlin, E., & Mossé, D. (1998). Ft-avs: a fault-tolerant architecture for real-time active vision. *Real-Time Imaging*, 4, 143–157.
- [Fernandez et al., 2002] Fernandez, C., Suardiaz, J., Jimenez, C., Navarro, P. J., Toledo, A., & Iborra, A. (2002). Automated visual inspection system for the classification of preserved vegetables. In *ISIE 2002. Proceedings of the 2002 IEEE International Symposium on Industrial Electronics*, number 1 (pp. 265–269).
- [Ferruz & Ollero, 2000] Ferruz, J. & Ollero, A. (2000). Integrated real-time vision system for vehicle control in non-structured environments. *Engineering Applications of Artificial Intelligence*, 13, 215–236.
- [Fowler, 2004] Fowler, M. (2004). *UML Distilled. A Brief Guide to the Standard Object Modeling Language*. Addison-Wesley, third edition edition.
- [Frangi et al., 2001] Frangi, A. F., Egmont-Petersen, M., Niessen, W. J., Reiber, J. H. C., & Viergever, M. A. (2001). Bone tumor segmentation from mr perfusion images with neural networks using multi-scale pharmacokinetic features. *Image and Vision Computing*, 19, 679–690.
- [Frosyniotis et al., 2003] Frosyniotis, D., Stafylopatis, A., & Likas, A. (2003). A divide-and-conquer method for multi-net classifiers. *Pattern Analysis and Applications*, 6, 32–40.
- [Gallegos-Hernandez et al., 2002] Gallegos-Hernandez, A., Ruiz-Sanchez, F. J., & Villalobos-Cano, J. R. (2002). 2d automated visual inspection system for the remote quality control of smd assembly. In *IECON 2002, 28th Annual Conference of the Industrial Electronics Society (IEEE)*, number 3 (pp. 2219–2224).
- [Garcia et al., 1999] Garcia, D. F., Garcia, M., Obeso, F., & Fernandez, V. (1999). Real-time flatness inspection system for steel strip productions lines. *Real Time Imaging*, 5, 35–47.
- [García et al., 2001] García, D. F., Usamentiaga, R., Marín, I., González, J. A., & de Abajo, N. (2001). Shape inspection system with real-time adaptation to the luminance of the objects. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection IX*, number 4301 (pp. 207–218). San Jose, USA.
- [Garcia-Alegre et al., 1995] Garcia-Alegre, M. C., Bustos, P., & Guinea, D. (1995). Complex behaviour generation on autonomous robots: a case study. In *IEEE*

- International Conference on Systems, Man and Cybernetics, 1995. 'Intelligent Systems for the 21st Century'*, number 2 (pp. 1729–1734).
- [García-Alegre et al., 2007] García-Alegre, M. C., Ribeiro, A., García-Pérez, L., Martín, D., & Guinea, D. (2007). Amara una arquitectura híbrida basada en agentes de comportamiento. In R. Aracil, M. Ferre, & M. A. Sánchez-Urán (Eds.), *Libro Proc. Workshop Arquitecturas de control para robots* (pp. 25–39). ETSII-Univ Politécnica de Madrid.
- [García-Alegre et al., 2000] García-Alegre, M. C., Ribeiro, A., Guinea, D., & Cristóbal, G. (2000). Eggshell defects detection based on color processing. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 280–287). San Jose, California.
- [García-Pérez, 2004] García-Pérez, L. (2004). *Navegación Autónoma de Robots en Agricultura: un Modelo de Agentes*. Tesis doctoral, Facultad de Ciencias Físicas. Universidad Complutense de Madrid.
- [Gershenson, 2004] Gershenson, C. (2004). Cognitive paradigms: which one is the best? *Cognitive Systems Research*, 5, 135–156.
- [Geveaux et al., 2000] Geveaux, P., Kohler, S., Miteran, J., Truchetet, F., & Meriaudeau, F. (2000). Comparison between two classification methods, application to defects detection by artificial vision in industrial field. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 154–161). San Jose, California.
- [Giacinto & Roli, 2001] Giacinto, G. & Roli, F. (2001). Desing of effective neural network ensembles for image classification purposes. *Image and Vision Computing*, 19, 699–707.
- [Govindaraju et al., 2001] Govindaraju, M., Pennathur, A., & Mital, A. (2001). Quality improvement in manufacturing through human performance enhancement. *Integrated Manufacturing Systems*, 12, 360–368.
- [Grim et al., 2002] Grim, J., Kittler, J., Pudil, P., & Somol, P. (2002). Multiple classifier fusion in probabilistic neural networks. *Pattern Analysis and Applications*, 5, 221–233.
- [Guda et al., 2000] Guda, P., Cao, J., Gailey, J., & Hall, E. L. (2000). Machine vision fundamentals. In R. L. Shell & E. L. Hall (Eds.), *Handbook of Industrial Automation* (pp. 1–61). New York: Marcel Dekker.
- [Guinea et al., 1993] Guinea, D., Garcia-Alegre, M. C., Ibáñez, A., Bustos, P., & Barrios, L. J. (1993). Competitividad, cooperación y jerarquía entre agentes autónomos de comportamiento. In *Proc. 3er Congreso en Robótica y Automatización Avanzada* (pp. 61–68). Zaragoza.

- [Guinea et al., 2000] Guinea, D., Preciado, V. M., Vicente, J., Ribeiro, A., & García-Alegre, M. C. (2000). Cnn based visual processing for industrial inspection. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 315–322). San Jose, California.
- [Guinea et al., 1997] Guinea, D., Recio, F., & Vicente, J. (1997). Framing autonomy: A visual tracking architecture. In *Agents97 Conference Proceedings, ACM*.
- [Guinea et al., 1991] Guinea, D., Ruiz, A., & Barrios, L. J. (1991). Multi-sensor integration – an automatic feature selection and state identification methodology for tool wear estimation. *Computers in Industry*, 17, 121–130.
- [Guinea et al., 1995] Guinea, D., Sanchez, G., Bustos, P., & Garcia-Alegre, M. (1995). A distributed architecture for active perception in autonomous robots. In *IEEE International Conference on Systems, Man and Cybernetics* (pp. 1740–1745).
- [Haering & da Victoria Lobo, 1999] Haering, N. & da Victoria Lobo, N. (1999). Features and classification methods to locate deciduous trees in images. *Computer Vision and Image Understanding*, 75, 133–149.
- [Hakulinen & Hakkarainen, 1996] Hakulinen, A. & Hakkarainen, J. (1996). A neural network approach to quality control of padlock manufacturing. *Pattern Recognition Letters*, 17, 357–362.
- [Han et al., 2001] Han, L., Richard, K., Michael, H., Chandler, P., & Nathan, B. (2001). Using cognitive models for adaptive control and display. *Automedica*, 19, 211–239.
- [Haralick & Shapiro, 1985] Haralick, R. M. & Shapiro, L. G. (1985). Image segmentation techniques. *Computer, Vision, Graphics and Image Processing*, 29, 100–133.
- [Hecht & Zajac, 1986] Hecht, E. & Zajac, A. (1986). *Optica*. Addison-Wesley Iberoamericana.
- [Hogert et al., 1997] Hogert, E.Ñ., Landau, M. R., & Gaggioli, N. G. (1997). Micrometrología óptica de superficies rugosas. In *CORENDE* (pp. 183–192).
- [Hou et al., 2005] Hou, Z., Li, J., & Parker, J. M. (2005). Real-time automated visual inspection of fabrics inhomogeneities. In *International Conference on Advanced Intelligent Mechatronics* (pp. 360–365). Monterey, California, USA.
- [Howell & Buxton, 2002] Howell, A. J. & Buxton, H. (2002). Active vision techniques for visually mediated interaction. *Image and Vision Computing*, 20, 861–871.

- [Hsu & Tseng, 2001] Hsu, J.-H. & Tseng, C.-S. (2001). Application of three-dimensional orthogonal neural network to craniomaxillary reconstruction. *Computerized Medical Imaging and Graphics*, 25, 477–482.
- [Hu et al., 2002] Hu, T., De Silva, L. C., & Sengupta, K. (2002). A hybrid approach of nn and hmm for facial emotion classification. *Pattern Recognition Letters*, 23, 1303–1310.
- [Hu & Hwang, 2002] Hu, Y. H. & Hwang, J.Ñ. (2002). *Handbook of neural network signal processing*. CRC Press.
- [Huang & Huang, 1998] Huang, C.-L. & Huang, W.-Y. (1998). Sign language recognition using model-based tracking and a 3d hopfield neural network. *Machine Vision and Applications*, 10, 292–307.
- [Jahne et al., 1999] Jahne, B., Haubecker, H., & Geibler, P. (1999). *Handbook of Computer Vision and Applications. Volume 1 Sensors and Imaging*. Academic Press.
- [Jiang & Jiang, 1998] Jiang, B. C. & Jiang, S. J. (1998). Machine vision based inspection of oil seals. *Journal of Manufacturing Systems*, 17, 159–166.
- [Jiménez et al., 1999] Jiménez, A. R., Jain, A. K., Ceres, R., & Pons, J. L. (1999). Automatic fruit recognition: a survey and new results using range/attenuation images. *Pattern Recognition*, 32, 1719–1736.
- [Jung & Han, 2004] Jung, K. & Han, J. (2004). Hybrid approach to efficient text extraction in complex color images. *Pattern Recognition Letters*, 25, 679–699.
- [Kang & Liu, 2005] Kang, G.-W. & Liu, H.-B. (2005). Surface defects inspection of cold rolled strips based on neural network. In *Proceedings of 2005 International Conference on Machine Learning and Cybernetics*, number 8 (pp. 5034–5037).
- [Khandogin et al., 1997] Khandogin, I., Kummert, A., & Maiwald, D. (1997). Automatic damage detection for railroad tracks by the analysis of video images. In *International Conference on Signal Processing Applications and Technology (ICSPAT97)*.
- [Kobashi et al., 2001] Kobashi, S., Kamiura, N., Hata, Y., & Miyawaki, F. (2001). Volume-quantization-based neural network approach to 3d mr angiography image segmentation. *Image and Vision Computing*, 19, 185–193.
- [Kohler et al., 2001] Kohler, S., Geveaux, P., & Miteran, J. (2001). New filter for detecting defects on industrial parts by artificial vision. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection IX*, number 4301 (pp. 73–83). San Jose, USA.

- [Kopardekar et al., 1993] Kopardekar, P., Mital, A., & Anand, S. (1993). Manual, hybrid and automated inspection literature and current research. *Integrated Manufacturing Systems*, 4, 18–29.
- [Kouzani, 2003] Kouzani, A. Z. (2003). Locating human faces within images. *Computer Vision and Image Understanding*, 91, 247–279.
- [Kuniyoshi & Inoue, 1993] Kuniyoshi, Y. & Inoue, H. (1993). Qualitative recognition of ongoing human action sequences. In *IJCAI-93. Proceedings of the Thirteenth International Joint Conference on Artificial Intelligence*, number 2 (pp. 1600–1609). Chambery, France.
- [Kushleyeva et al., 2005] Kushleyeva, Y., Salvucci, D. D., & Lee, F. J. (2005). Deciding when to switch tasks in time-critical multitasking. *Cognitive Systems Research*, 6, 41–49.
- [Lacey et al., 1998] Lacey, A. J., Thacker, N. A., Crossley, S., & Yates, R. B. (1998). A multi-stage approach to the dense estimation of disparity from stereo sem images. *Image and Vision Computing*, 16, 373–383.
- [Lahajnar & Kovacic, 2000] Lahajnar, F. & Kovacic, S. (2000). Machine vision system for positioning and part verification of gas oil filters based on eigenimages. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 220–227). San Jose, California.
- [Laird et al., 1987] Laird, J. E., Newell, A., & Rosenbloom, P. S. (1987). Soar: An architecture for general intelligence. *Artificial Intelligence*, 33, 1–64.
- [Laizola et al., 2003] Laizola, E., Jiménez, A. R., Morgado, F., Calvache, M., & Seco, F. (2003). Computer-vision-based gob inspection system for monitoring and control in glass industry. In *Proceedings of Electronic Imaging Machine Vision Applications in Industrial Inspection XI*, number 5011 (pp. 90–100). Santa Clara, California, USA.
- [Langenbach et al., 2001] Langenbach, R., Ohl, A., Scharf, P., & Semmler, J. (2001). Automatic visual inspection system for small stampings with free-form surfaces. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection IX*, number 4301 (pp. 9–19). San Jose, USA.
- [Lavagno et al., 2003] Lavagno, L., Martin, G., & Selic, B. (2003). *UML for Real. Design of Embedded Real-Time Systems*. Kluwer Academic Publishers.
- [Lecerf et al., 2000] Lecerf, A., Ouellet, D., & Arias-Estrada, M. (2000). Computer vision camera with embedded fpga processing. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 299–308). San Jose, California.

- [Leclerc & Zucker, 1987] Leclerc, Y. G. & Zucker, S. W. (1987). The local structure of image discontinuities in one-dimension. *IEEE Trans. Pattern Anal. Machine Intell.*, 9, 341–355.
- [Lehotsky, 2000] Lehotsky, D. A. (2000). Intelligent high sensitivity ccd line scan camera with embedded image processing algorithms. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 40–47). San Jose, California.
- [Li & Lin, 1994] Li, H. & Lin, J. C. (1994). Using fuzzy logic to detect dimple defects of polished wafer surfaces. *IEEE Transactions on Industry Applications*, 30, 317–323.
- [López et al., 2006] López, M. T., Fernández-Caballero, A., Mira, J., Delgado, A. E., & Fernández, M. A. (2006). Algorithmic lateral inhibition method in dynamic and selective visual attention task: Application to moving objects detection and labelling. *Expert Systems with Applications*, 31, 570–594.
- [Lurette & Lecoeuche, 2003] Lurette, C. & Lecoeuche, S. (2003). Unsupervised and auto-adaptive neural architecture for on-line monitoring. application to a hydraulic process. *Engineering Applications of Artificial Intelligence*, 16, 441–451.
- [Malamas et al., 2003] Malamas, E.Ñ., Petrakis, E. G. M., Zervakis, M., Petit, L., & Legat, J. D. (2003). A survey on industrial vision systems, applications and tools. *Image and Vision Computing*, 21, 171–188.
- [Mamdani, 1976] Mamdani, E. H. (1976). Advances in the linguistic synthesis of fuzzy controllers. *International Journal of Man-Machine Studies*, 8, 669–678.
- [Mamdani, 1977] Mamdani, E. H. (1977). Applications of fuzzy logic to approximate reasoning using linguistic synthesis. *IEEE Transactions on Computers*, 26, 1182–1191.
- [Mamdani & Assilian, 1975] Mamdani, E. H. & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7, 1–13.
- [Maravall Gómez-Allende, 1993] Maravall Gómez-Allende, D. (1993). *Reconocimiento de Formas y Visión Artificial*. RA-MA.
- [Marr, 1982] Marr, D. (1982). *Vision: A computational investigation into the human representation and processing of visual information*. New York: W.H. Freeman publ.
- [Martín et al., 2004] Martín, D., García, G., González, L., Agila, W. E., Rubio, M. A., García, A. J., Villanueva, E., Barrera, F., Valiño, L., & Guinea, D. (2004). Análisis de imagen para validación de modelos fluido-dinámicos de la distribución

- de flujo de metanol. In *Actas del I Congreso Nacional de Pilas de Combustible y Tecnologías del Hidrógeno, (Conappice2004)* (pp. 174–177). Parque Tecnológico de Miramón, San Sebastián.
- [Martín et al., 2006] Martín, D., Guinea, D. M., Moreno, B., González, L., García-Alegre, M. C., & Guinea, D. (2006). Electric modelling and image analysis of channel flow in bipolar plates. *International Journal of Hydrogen Energy*, Doi: 10.1016/j.ijhydene.2006.10.042.
- [Martín et al., 2003a] Martín, D., Villanueva, E., & Guinea, D. (2003a). Properties of the steel reflectance and steel inspection with photoelectric sensor. In *Proceedings of 13th International Symposium on Measurement and Control in Robotics* (pp. 107–109). Madrid.
- [Martín et al., 2003b] Martín, D., Villanueva, E., & Guinea, D. (2003b). *Prototipo para inspección de cascarilla basado en sensores fotoeléctricos*. Informe técnico, departamento de sistemas (iai-csic) (tr-06-03), Instituto de Automática Industrial (IAI-CSIC), Arganda del Rey, Madrid.
- [Martín et al., 2003c] Martín, D., Villanueva, E., Guinea, D., Spinola, C., Espejo, S., & Morillas, S. (2003c). *Estudio sobre la metodología a emplear para la detección y clasificación de cascarilla residual en línea de producción*. Informe técnico, departamento de sistemas (iai-csic) (tr-04-03), Instituto de Automática Industrial (IAI-CSIC), Universidad de Málaga, Instituto de Microelectrónica de Sevilla (IMSE-CNM-CSIC), TCC S.A., Anafocus S.L., Arganda del Rey, Madrid.
- [Maurer & Dickmanns, 1997] Maurer, M. & Dickmanns, E. D. (1997). A system architecture for autonomous visual road vehicle guidance. In *IEEE Conference on Intelligent Transportation System* (pp. 578–583).
- [McCormick et al., 1982] McCormick, B. H., Kent, E., & Dyer, C. R. (1982). A cognitive architecture for computer vision. In *Fifth Generation Computer Systems. Proceedings of the International Conference* (pp. 245–309). Tokyo, Japan.
- [Meriaudeau & C., 2000] Meriaudeau, F. & C., L. A. (2000). Machine vision systems in metallurgy industry. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 228–237). San Jose, California.
- [Mery, 2002] Mery, D. (2002). Inspección visual automática. In *Primer Congreso Internacional de Ingeniería Mecatrónica* Lima, Perú.
- [Miller et al., 1996] Miller, W., Jaskot, J., McCoy, B., & Schiller, E. (1996). A distributed system for 100 In *International Conference on Signal Processing Applications and Technology (ICSPAT96)*.
- [Mira et al., 2004] Mira, J., Delgado, A. E., Fernández-Caballero, A., & Fernández, M. A. (2004). Knowledge modelling for the motion detection task: the algorithmic lateral inhibition method. *Expert Systems with Applications*, 27, 169–185.

- [Mital et al., 1998] Mital, A., Govindaraju, M., & Subramani, B. (1998). A comparison between manual and hybrid methods in parts inspection. *Integrated Manufacturing Systems*, 9, 344–349.
- [Moganti et al., 1996] Moganti, M., Ercal, F., Dagli, C. H., & Tsunekawa, S. (1996). Automatic pcb inspection algorithms: A survey. *Computer Vision and Image Understanding*, 63, 287–313.
- [Montúfar-Chaveznava et al., 2001a] Montúfar-Chaveznava, R., Guinea, D., García-Alegre, M. C., & Preciado, V. M. (2001a). Cnn computer for high speed visual inspection. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection IX*, number 4301 (pp. 236–243). San Jose, USA.
- [Montúfar-Chaveznava et al., 2001b] Montúfar-Chaveznava, R., Guinea, D., García-Alegre, M. C., & Preciado, V. M. (2001b). Image coding by cellular neural networks. In *Proceedings of SPIE Applications of Artificial Neural Networks in Image Processing VI*, number 4305 (pp. 160–167). San Jose, USA.
- [Motta, 1999] Motta, E. (1999). *Reusable Components for Knowledge Modelling. Case Studies in Parametric Design Problem Solving*. IOS Press.
- [Nalwa & Binford, 1986] Nalwa, V. S. & Binford, T. O. (1986). On detecting edges. *IEEE Trans. Pattern Anal. Machine Intell.*, 8, 699–714.
- [Nason & Laird, 2005] Nason, S. & Laird, J. E. (2005). Soar-rl: integrating reinforcement learning with soar. *Cognitive Systems Research*, 6, 51–59.
- [NeuroCheck, 2006] NeuroCheck (2006). NeuroCheck. Industrial Vision Systems. Version 5,1,1065[SP9]. NeuroCheck GmbH.
- [Newman & Jain, 1995] Newman, T. S. & Jain, A. K. (1995). A survey of automated visual inspection. *Computer Vision and Image Understanding*, 61, 231–262.
- [Ng & Ranganath, 2002] Ng, C. W. & Ranganath, S. (2002). Real-time gesture recognition system and application. *Image and Vision Computing*, 20, 993–1007.
- [Noordam et al., 2000] Noordam, J. C., Otten, G. W., Timmermans, A. J. M., & van Zwol, B. H. (2000). High speed potato grading and quality inspection based on a color vision system. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 206–217). San Jose, California.
- [Okada et al., 2002] Okada, S., Mori, Y., Tominaga, R., & Mise, T. (2002). Development of a high-resolution surveillance camera with 520 tv lines. In *Proceedings of SPIE Sensors and Camera Systems for Scientific, Industrial and Digital Photography Applications III*, number 4669 (pp. 63–71).
- [OpenCV, 2001] OpenCV (2001). Open Source Computer Vision Library. Reference Manual. Intel Corporation.

- [Optics-Guide, 1999] Optics-Guide (1999). User's Guide. Melles Griot.
- [Packianathe & Park, 2000] Packianathe, M. S. & Park, P. R. (2000). Neural networks for classifying images of wood veneer. part 2. *International Journal of Advanced Manufacturing Technology*, 16, 424–433.
- [Papamarkos et al., 2000] Papamarkos, N., Strouthopoulos, C., & Andreadis, I. (2000). Multithresholding of color and gray-level images through a neural network technique. *Image and Vision Computing*, 18, 213–222.
- [Pasquariello et al., 1998] Pasquariello, G., Satalino, G., la Forgia, V., & Spilotros, F. (1998). Automatic target recognition for naval traffic control using neural networks. *Image and Vision Computing*, 16, 67–73.
- [Pessoa & Maragos, 2000] Pessoa, L. F. C. & Maragos, P. (2000). Neural networks with hybrid morphological/rank/linear nodes: a unifying framework with applications to handwritten character recognition. *Pattern recognition*, 33, 945–960.
- [Pham & Alcock, 1997] Pham, D. T. & Alcock, R. J. (1997). Automated visual inspection of birch wood boards. *IEE Colloquium on Artificial Intelligence in Manufacturing*, (Digest No: 1997/060), 1–4.
- [Pham & Alcock, 2003] Pham, D. T. & Alcock, R. J. (2003). *Smart Inspection Systems. Techniques and Applications of Intelligent Vision*. Academic Press.
- [Poseidon, 2006] Poseidon (2006). Poseidon for UML Professional Edition 4.1-0. Genteware AG.
- [Poujouly & Journet, 2002] Poujouly, S. & Journet, B. (2002). Smart sensor for surface inspection: concepts and prototype description. In *Proceedings of SPIE Sensors and Camera Systems for Scientific, Industrial and Digital Photography Applications III*, number 4669 (pp. 207–216).
- [Preciado et al., 2001a] Preciado, V. M., Guinea, D., & Montúfar, R. (2001a). Automatic generation of multipath algorithms in the cellular nonlinear network. In *Proceedings of SPIE Applications of Artificial Neural Networks in Image Processing VI*, number 4305 (pp. 149–159). San Jose, USA.
- [Preciado et al., 2001b] Preciado, V. M., Guinea, D., Montúfar, R., & Vicente, J. (2001b). Real-time inspection of metal laminates by means of cnn's. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection IX*, number 4301 (pp. 260–269). San Jose, USA.
- [ProVision, 2003] ProVision (2003). ProVision Version 2.1 (Machine Vision Software). Siemens AG.

- [Quintian et al., 1997] Quintian, F. P., Rebollo, M. A., Gaggioli, N. G., & Raffo, C. A. (1997). Estudio de la superficie de alambres mediante métodos ópticos. In *CORENDE* (pp. 255–257).
- [Raghu et al., 1995] Raghu, P., Poongodi, R., & Yegnanarayana, B. (1995). A combined neural network approach for texture classification. *Neural Networks*, 8, 975–987.
- [Rajab et al., 2004] Rajab, M. I., Woolfson, M. S., & Morgan, S. P. (2004). Application of region-based segmentation and neural network edge detection to skin lesions. *Computerized Medical Imaging and Graphics*, 28, 61–68.
- [Rao & Ballard, 1995] Rao, R. P.Ñ. & Ballard, D. H. (1995). An active vision architecture based on iconic representations. *Artificial Intelligence*, 78, 461–505.
- [Ribeiro et al., 2003] Ribeiro, A., André, G., Rabe, C., Martín, D., & García-Alegre, M. C. (2003). *Procesamiento de Imagen para el cálculo del Tanto por Ciento de Infestación de Malas Hierbas*. Informe técnico, departamento de sistemas (iaicsic) (tr-07-03), Instituto de Automática Industrial (IAI-CSIC), Arganda del Rey, Madrid.
- [Rincón, 2002] Rincón, M. (2002). *Interpretación de imágenes basada en modelos de conocimiento: Aplicación a la identificación de la cabeza del nervio óptico en DIAGEN*. Tesis doctoral, Facultad de Ciencias. Universidad Nacional de Educación a Distancia.
- [Rincón et al., 2005a] Rincón, M., Bachiller, M., & Mira, J. (2005a). Knowledge modeling for the image understanding task as a design task. *Expert Systems with Applications*, 29, 207–217.
- [Rincón et al., 2005b] Rincón, M., Lafuente-Arroyo, S., & Maldonado-Bascón, S. (2005b). Knowledge modeling for the traffic sign recognition task. In J. Mira & J. R. Álvarez (Eds.), *Proceedings of IWINAC 2005*, number 3561 (pp. 508–517).: Springer-Verlag Berlin Heidelberg 2005.
- [Riviere et al., 2002] Riviere, D., Mangin, J.-F., Papadopoulos-Orfanos, D., Martinez, J.-M., Frouin, V., & Regis, J. (2002). Automatic recognition of cortical sulci of the human brain using a congregation of neural networks. *Medical Image Analysis*, 6, 77–92.
- [Roh et al., 2003] Roh, Y. J., Park, W. S., & Cho, H. (2003). Correcting image distortion in the x-ray digital tomosynthesis system for pcb solder joint inspection. *Image and Vision Computing*, 21, 1063–1075.
- [Rosenbloom et al., 1991] Rosenbloom, P. S., Laird, J. E., Newell, A., & McCarl, R. (1991). A preliminary analysis of the soar architecture as a basis for general intelligence. *Artificial Intelligence*, 47, 289–325.

- [Rosenfeld, 2000a] Rosenfeld, A. (2000a). Classifying the literature related to computer vision and image analysis. *Computer Vision and Image Understanding*, 79, 308–323.
- [Rosenfeld, 2000b] Rosenfeld, A. (2000b). Survey. image analysis and computer vision: 1999. *Computer Vision and Image Understanding*, 78, 222–302.
- [Rosenfeld, 2001] Rosenfeld, A. (2001). From image analysis to computer vision: An annotated bibliography, 1955-1979. *Computer Vision and Image Understanding*, 84, 298–324.
- [Rosenfeld et al., 1976] Rosenfeld, A., Hummel, R. A., & Zucker, S. U. (1976). Scene labelling by relaxation operations. *IEEE Trans. Syst. Man Cybern.*, (pp. 420–433).
- [Ruichek & Postaire, 1999] Ruichek, Y. & Postaire, J.-G. (1999). A new neural real-time implementation for obstacle detection using linear stereo vision. *Real-Time Imaging*, 5, 141–153.
- [Sams & Hansen, 2000] Sams, T. & Hansen, J. L. (2000). Implications of physical symmetries in adaptive image classifiers. *Neural networks*, 13, 565–570.
- [Sanches & Piedade, 1997] Sanches, J. M. R. & Piedade, M. S. (1997). An automatic visual inspection system of the quality of painting of metal film mini resistors. In *International Conference on Signal Processing Applications and Technology (ICSPAT97)*.
- [Sanz & Petkovic, 1988] Sanz, J. & Petkovic, D. (1988). Machine vision algorithm for automated inspection of thin-film disk heads. *IEEE Transactions on PAMI*, 10, 830–848.
- [Schlicke, 2001] Schlicke, T. (2001). *Breaking Waves and the Dispersion of Surface Films*. PhD thesis, University of Edinburgh.
- [Schreiber et al., 2000] Schreiber, G., Akkermans, H., Anjewierden, A., de Hoog, R., Shadbolt, N., de Velde, W. V., & Wielinga, B. (2000). *Knowledge Engineering and Management: The CommonKADS Methodology*. The MIT Press.
- [Seulin et al., 2001] Seulin, R., Merienne, F., & Gorria, P. (2001). Dynamic lighting system for specular surface inspection. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection IX*, number 4301 (pp. 199–206). San Jose, USA.
- [Shafarenko et al., 1997] Shafarenko, L., Petrou, M., & Kittler, J. (1997). Automatic watershed segmentation of randomly textured color images. *IEEE Transactions on Image Processing*, 6, 1530–1543.
- [Shekhar et al., 1997] Shekhar, C., Burlina, P., & Moisan, S. (1997). Design of self-tuning iu systems. In *DARPA Image Understanding Workshop* (pp. 529–536).

- [Shekhar et al., 1996] Shekhar, C., Kuttikkad, S., & Chellappa, R. (1996). Knowledge-based integration of iu algorithms. In *Proceedings of Image Understanding Workshop* (pp. 1525–1532).
- [Shekhar et al., 1999] Shekhar, C., Moisan, S., Vincent, R., Burlina, P., & Chellappa, R. (1999). Knowledge-based control of vision systems. *Image and Vision Computing*, 17, 667–683.
- [Siegmann et al., 2004a] Siegmann, P., Martínez-Antón, J. C., & Bernabeu, E. (2004a). Static and dynamic detection of axial surface defects on metallic wires by conical triple laser reflection. *Optics and Lasers in Engineering*, 42, 203–218.
- [Siegmann et al., 2004b] Siegmann, P., Sanchez-Brea, L. M., Martinez-Anton, J. C., & Bernabeu, E. (2004b). Comparison between optical techniques and confocal microscopy for defect detection on thin wires. *Applied Surface Science*, 238, 375–379.
- [Silvén et al., 2003] Silvén, O., Niskanen, M., & Kauppinen, H. (2003). Wood inspection with non-supervised clustering. *Machine Vision and Applications*, 13, 275–285.
- [Smith & Smith, 2003] Smith, M. & Smith, L. (2003). Automated visual inspection for polished stone manufacture. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection XI*, number 5011 (pp. 297–306). Santa Clara, California, USA.
- [Smith, 2001] Smith, M. L. (2001). *Surface Inspection Techniques - Using the Integration of Innovative Machine Vision and Graphical Modelling Techniques*. Engineering Research Series. London and Bury St Edmunds, UK: Professional Engineering Publishing.
- [Smith et al., 1999] Smith, M. L., Smith, G., & Hill, T. (1999). Gradient space analysis of surface defects using a photometric stereo derived bump map. *Image and Vision Computing*, 17, 321–332.
- [Solberg, 2004] Solberg, A. H. S. (2004). Flexible nonlinear contextual classification. *Pattern Recognition Letters*, 25, 1501–1508.
- [Solina & Leonardis, 1998] Solina, F. & Leonardis, A. (1998). Proper scale for modeling visual data. *Image and Vision Computing*, 16, 89–98.
- [Stefik, 1995] Stefik, M. (1995). *Introduction to Knowledge Systems*. Morgan Kaufmann.
- [Stojanovic et al., 2001] Stojanovic, R., Mitropulos, P., Koulamas, C., Karayiannis, Y., Koubias, S., & Papadopoulos, G. (2001). Real-time vision-based system for textile fabric inspection. *Real-Time Imaging*, 7, 507–518.

- [Stokman & Gevers, 2000] Stokman, H. M. G. & Gevers, T. (2000). Color measurement by imaging spectrometry. *Computer Vision and Image Understanding*, 79, 236–249.
- [Su et al., 2003] Su, Z., Dehghani, A. A., Zhang, L., King, T., & Greenwood, B. (2003). A vision system for auto-detection of cashmere pigmented fibres. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection XI*, number 5011 (pp. 32–38). Santa Clara, California, USA.
- [Suganthan et al., 1997] Suganthan, P.Ñ., Teoh, E. K., & Mital, D. P. (1997). Optimal mapping of graph homomorphism onto self organising hopfield network. *Image and Vision Computing*, 15, 679–694.
- [Sun et al., 2006] Sun, R., Zhang, X., & Mathews, R. (2006). Modeling meta-cognition in a cognitive architecture. *Cognitive Systems Research*, 7, 327–338.
- [Sun & Fisher, 2003] Sun, Y. & Fisher, R. (2003). Object-based visual attention for computer vision. *Artificial Intelligence*, 146, 77–123.
- [Sutton, 1990] Sutton, R. S. (1990). Integrated architectures for learning, planning, and reacting based on approximating dynamic programming. In *Proceedings of the Seventh Int. Conf. on Machine Learning* (pp. 216–224).
- [Takatsuka & Jarvis, 2001] Takatsuka, M. & Jarvis, R. A. (2001). Encoding 3d structural information using multiple self-organizing feature maps. *Image and Vision Computing*, 19, 99–118.
- [Tan et al., 1999] Tan, T., Guan, L., & Burne, J. (1999). A real-time image analysis system for computer-assisted diagnosis of neurological disorders. *Real-Time Imaging*, 5, 253–269.
- [Tenenbaum, 1970] Tenenbaum, J. M. (1970). *Accommodation in computer vision*. PhD thesis, Stanford University.
- [Tobin et al., 2000] Tobin, K. W., Goddard, J. S., Hunt, M. A., Hylton, K. W., Karnowski, T. P., Simpson, M. L., Richards, R. K., & Treece, D. A. (2000). Accommodating multiple illumination sources in an imaging colorimetry environment. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection VIII*, number 3966 (pp. 194–205). San Jose, California.
- [Tolba & Abu-Rezq, 2000] Tolba, A. S. & Abu-Rezq, A.Ñ. (2000). Combined classifiers for invariant face recognition. *Pattern Analysis and Applications*, 3, 289–302.
- [Toolbox, 2004a] Toolbox (2004a). *Image Processing Toolbox 5.0.1*. User's Guide. 3 Apple Hill Drive, Natick, MA 01760-2098: The MathWorks, Inc.
- [Toolbox, 2004b] Toolbox (2004b). *Neural Network Toolbox 4.0*. User's Guide. 3 Apple Hill Drive, Natick, MA 01760-2098: The MathWorks, Inc.

- [Torres et al., 1998] Torres, T., Sebastian, J. M., Aracil, R., Jimenez, L. M., & Reinoso, O. (1998). Automated real-time visual inspection system for high-resolution superimposed printings. *Image and Vision Computing*, 16, 947–958.
- [Traver & Pla, 2005] Traver, V. J. & Pla, F. (2005). Similarity motion estimation and active tracking through spatial-domain projections on log-polar images. *Computer Vision and Image Understanding*, 97, 209–241.
- [Tsai et al., 1998] Tsai, D. M., Chen, J. J., & Chen, J. F. (1998). A vision system for surface roughness assessment using neural networks. *International Journal of Advanced Manufacturing Technology*, 14, 412–422.
- [Tsai & Hsieh, 1999] Tsai, D. M. & Hsieh, C. Y. (1999). Automated surface inspection for directional textures. *Image and Vision Computing*, 18, 49–62.
- [Tyugu, 2006] Tyugu, E. (2006). Understanding knowledge architectures. *Knowledge-Based Systems*, 19, 50–56.
- [Ukita & Matsuyama, 2005] Ukita, N. & Matsuyama, T. (2005). Real-time cooperative multi-target tracking by communicating active vision agents. *Computer Vision and Image Understanding*, 97, 137–179.
- [Vélez et al., 2003] Vélez, J. F., Moreno, A. B., Sánchez, A., & Esteban, J. L. (2003). *Visión por Computador*. DYKINSON.
- [Venkatachalam et al., 2003] Venkatachalam, V., Wasserman, R. M., Yoshida, H., Asano, H., & Takahama, Y. (2003). Effect of acquisition system features on algorithm performance. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection XI*, number 5011 (pp. 171–182). Santa Clara, California, USA.
- [Venkatesh & Kumar Raja, 2003] Venkatesh, Y. V. & Kumar Raja, S. (2003). On the classification of multispectral satellite images using the multilayer perceptron. *Pattern Recognition*, 36, 2161–2175.
- [Villmann et al., 2003] Villmann, T., Merenyi, E., & Hammer, B. (2003). Neural maps in remote sensing image analysis. *Neural networks*, 16, 389–403.
- [Waeny & Schwider, 2002] Waeny, M. & Schwider, P. M. (2002). Cmos megapixel digital camera with cameralink interface. In *Proceedings of SPIE Sensors and Camera Systems for Scientific, Industrial and Digital Photography Applications III*, number 4669 (pp. 137–144).
- [Wang et al., 2004] Wang, H., Fan, J., & Johnson, T. R. (2004). A symbolic model of human attentional networks. *Cognitive Systems Research*, 5, 119–134.
- [Whelan et al., 2001] Whelan, P. F., Soille, P., & Drimbarean, A. (2001). Real-time registration of paper watermarks. *Real-Time Imaging*, 7, 367–380.

- [Wohler & Anlauf, 1999] Wohler, C. & Anlauf, J. K. (1999). A time delay neural network algorithm for estimating image-pattern shape and motion. *Image and Vision Computing*, 17, 281–294.
- [Wohler & Anlauf, 2001] Wohler, C. & Anlauf, J. K. (2001). Real-time object recognition on image sequences with the adaptable time delay neural network algorithm - applications for autonomous vehicles. *Image and Vision Computing*, 19, 593–618.
- [Xu & Hogg, 1997] Xu, L.-Q. & Hogg, D. C. (1997). Neural networks in human motion tracking - an experimental study. *Image and Vision Computing*, 15, 607–615.
- [Young, 2005] Young, R. M. (2005). The data learning problem in cognitive architectures. *Cognitive Systems Research*, 6, 89–97.
- [Zhang et al., 2003] Zhang, L., Dehghani, A., Su, Z., King, T., & Greenwood, B. (2003). Identification of white contaminants and their removal from wool fibers. In *Proceedings of SPIE Machine Vision Applications in Industrial Inspection XI*, number 5011 (pp. 22–31). Santa Clara, California, USA.
- [Zhou, 1999] Zhou, S. M. (1999). Combining dynamic neural networks and image sequences in a dynamic model for complex industrial production processes. *Expert Systems with Applications*, 16, 13–19.
- [Zuech, 2000] Zuech, N. (2000). *Understanding and Applying Machine Vision*. Marcel Dekker, Inc., second edition, revised and expanded edition.