



UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA

Doctorado en Informática

**Departamento de Informática y Sistemas
Programa de Doctorado: "Percepción Artificial y Aplicaciones"**


**Título de la Tesis:
"Estructuras de representación visual múltiple.
Aplicación a la detección de variaciones locales en
texturas y a la inspección visual "**

**Tesis Doctoral presentada por D. Carmelo Rubén García Rodríguez
Dirigida por el Dr. D. Santiago Candela Solá**

El Doctorando,

El Director,

Las Palmas de Gran Canaria, a 8 de Noviembre 1994



AGRADECIMIENTOS

Quiero expresar mi profundo agradecimiento a mi Director de Tesis Dr. D. Santiago Candela Solá por su ayuda tanto científica como moral, ya que sin este apoyo no habrá sido posible la realización de esta Tesis. También debo mencionar la inestimable ayuda de todos los miembros del Grupo de Investigación de Visión Artificial y Natural del Departamento de Informática y Sistemas de la Universidad de Las Palmas de Gran Canaria, especialmente la de Dr. D. José Antonio Muñoz Blanco y D. Francisco Alayón Hernández con quienes he formado equipo, junto con mi Director, durante estos últimos años. Además, debo mencionar mi reconocimiento hacia el Profesor D. Roberto Moreno Díaz por sus ideas y orientaciones que nos han servido considerablemente para establecer las bases de esta Tesis. Por último, agradecer el apoyo recibido en todo momento por parte del Departamento de Informática y Sistemas de esta Universidad.

A Teresa y a mis padres

ÍNDICE GENERAL.

II

RESUMEN.

I. INTRODUCCIÓN .	2
II. OBJETIVOS.	3
III. ESTRUCTURACIÓN DE LA MEMORIA.	4

CAPÍTULO 1.

LOS SISTEMAS DE INSPECCIÓN VISUAL AUTOMÁTICA.

1.1. FUNDAMENTOS DE LA VISIÓN ARTIFICIAL.	10
1.1.1. Objetivos.	10
1.1.2. Un modelo para la Visión Artificial.	12
1.2. SISTEMAS DE VISIÓN PARA LA INSPECCIÓN AUTOMÁTICA.	14
1.2.1. Fundamentos.	14
1.2.2. Revisión histórica.	21

CAPÍTULO 2.

METODOLOGÍA Y ESTRATEGIA GENERAL PARA LA DETECCIÓN AUTOMÁTICA DE CAMBIOS DE TEXTURA.

2.1. PARADIGMA.	36
2.1.1. Introducción.	36
2.1.2. Marco general.	38
2.1.3. Formulación del modelo.	43
2.1.4. Interpretación del modelo planteado.	46
2.2. MARCO ESPECÍFICO.	48
2.2.1. Construcción de la muestra significativa.	48
2.2.2. Mejora de la imagen a analizar.	51
2.2.2.1. Ecuación del histograma.	52
2.2.2.2. Proceso Facilitador.	54
2.2.3. Definición del área local de trabajo.	73
2.2.4. Cómputo de descriptores.	89
2.2.5. Cálculo del grado de homogeneidad local.	96
2.2.6. Reglas de decisión.	109

CAPÍTULO 3.**MÉTODOS PARA LA CREACIÓN DE IMÁGENES DE DESCRIPTORES.**

3.1. TÉCNICAS ESTADÍSTICAS PARA LA PRODUCCIÓN DE DESCRIPTORES.	120
3.1.1. Parámetros estadísticos de primer orden.	120
3.1.2. Parámetros basados en la Teoría de la Información.	121
3.1.3. Métricas entre histogramas.	122
3.1.4. Distribuciones de segundo orden: Matrices de Co-ocurrencia.	123
3.1.4.1. Descriptores basados en las Matrices de Co-ocurrencia.	126
3.1.4.2. Caracterización por Matrices de Co-ocurrencia.	129
3.1.5. Distribuciones de diferencias de niveles de gris.	131
3.2. PRODUCCIÓN DE DESCRIPTORES A PARTIR DE PROPIEDADES TOPOGRÁFICAS.	132
3.3. GENERACIÓN DE DESCRIPTORES POR TRANSFORMACIONES LINEALES.	137
3.4. DESCRIPTORES DE FOURIER.	140
3.5. OBTENCIÓN DE DESCRIPTORES MEDIANTE TRANSFORMACIONES ALGORÍTMICAS.	141
3.6. DESCRIPTORES SUPERVISADOS.	143

CAPÍTULO 4.**CASUÍSTICA, EXPERIMENTACIÓN Y PROTOTIPOS.**

4.1. COMPORTAMIENTO DE LOS DESCRIPTORES UTILIZADOS.	150
4.1.1. Estadísticos de primer orden.	152
4.1.2. Descriptores basados en la Teoría de la Información.	161
4.1.3. Métricas entre histogramas.	169
4.1.4. Estadísticos de segundo orden (Matrices de Co-ocurrencia).	179
4.1.5. Núcleos lineales.	189
4.2. PROTOTIPOS DE SISTEMAS PARA LA DETECCIÓN DE DEFECTOS.	197

CAPÍTULO 5.**APORTACIONES Y CONCLUSIONES.**

5.1. APORTACIONES Y CONCLUSIONES CONCEPTUALES.	228
5.2. APORTACIONES Y CONCLUSIONES PRÁCTICAS.	230
5.3. LÍNEA FUTURA DE TRABAJO.	231

REFERENCIAS.**RELACIÓN DE FIGURAS.**

Figura 1.1. Estructura común de un sistema de visión de inspección automática.	19
Figura 2.1. Modelo general.	40
Figura 2.2. Estrategia general.	41
Figura 2.3. Esquema de procesos.	42
Figura 2.4. Respuesta ante un pulso de entrada.	57
Figura 2.5. Respuesta ante una rampa de entrada.	58
Figura 2.6. Pulso genérico.	58
Figura 2.7. Forma de la respuesta general en el Caso 1.	59
Figura 2.8. Forma de la respuesta general en el Caso 2.	60
Figura 2.9. Forma de la respuesta general en el Caso 3.	60
Figura 2.10. Forma de la respuesta general en el Caso 4.	61
Figura 2.11. Respuesta ante una rampa con ruido.	61
Figura 2.12. Rampa degradada con ruido gaussiano.	62
Figura 2.13. Respuesta y $E(x)$ para la rampa degradada.	63
Figura 2.14. Red de cómputo paralelo del método.	65
Figura 2.15. Media: comportamiento ante distintas dimensiones de la ventana.	81
Figura 2.16. Varianza: Comportamiento ante la dimensión de la ventana.	81
Figura 2.17. Distancia euclídea frente a la dimensión de la ventana.	82
Figura 2.18. Distancia de Bhacharyya frente a la dimensión de la ventana.	82
Figura 2.19. Esferoide según distancia d_{ABS} .	101
Figura 2.20. Esferoide según distancia d_l .	102
Figura 2.21. Distancia local.	111
Figura 4.1. Diagrama de Bloques utilizando el Proceso Facilitador.	200

RELACIÓN DE ILUSTRACIONES (IMÁGENES).

Ilustración 2.1. Resultado del preproceso para un área local ...	67
Ilustración 2.2. Resultado del preproceso para un área local ...	69
Ilustración 2.3. Resultado del preproceso para un área local ...	71
Ilustración 2.4. Zona seleccionada para el estudio de la dimensión ...	79
Ilustración 2.5. Distancia euclídea. Fases del proceso de diagnóstico ...	83
Ilustración 2.6. Distancia euclídea. Fases del proceso de diagnóstico ...	85
Ilustración 2.7. Distancia euclídea. Fases del proceso de diagnóstico ...	87
Ilustración 2.8. Comportamiento de la diferencia relativa.	105
Ilustración 2.9. Comportamiento de la diferencia relativa.	107
Ilustración 2.10. Imagen Original en parte superior izquierda, imagen de medias ...	113
Ilustración 2.11. Superior izquierda imagen original, diagnóstico según medias ...	115
Ilustración 2.12. Superior izquierda imagen original, diagnóstico según medias ...	117
Ilustración 4.1. Diagnóstico producido por el parámetro media	153
Ilustración 4.2. Diagnóstico producido por el parámetro varianza ...	155
Ilustración 4.3. Diagnóstico producido por el parámetro curtosis ...	157
Ilustración 4.4. Diagnóstico producido por el parámetro apuntamiento ...	159
Ilustración 4.5. Diagnóstico producido por el parámetro energía ...	163
Ilustración 4.6. Diagnóstico producido por el parámetro sinergia ...	165
Ilustración 4.7. Diagnóstico producido por el parámetro entropía ...	167
Ilustración 4.8. Diagnóstico producido por el parámetro distancia euclídea ...	171
Ilustración 4.9. Diagnóstico producido por el parámetro test χ^2 ...	173
Ilustración 4.10. Diagnóstico producido por el parámetro distancia de Bhattacharyya ...	175
Ilustración 4.11. Diagnóstico producido por el parámetro distancia de Mahalanobis ...	177
Ilustración 4.12. Diagnóstico producido por el parámetro energía ...	181
Ilustración 4.13. Diagnóstico producido por el parámetro homogeneidad ...	183
Ilustración 4.14. Diagnóstico producido por el parámetro inercia ...	185
Ilustración 4.15. Diagnóstico producido por el parámetro energía ...	187
Ilustración 4.16. Diagnóstico producido por el parámetro máscara L31S31	191
Ilustración 4.17. Diagnóstico producido por el parámetro máscara K1	193
Ilustración 4.18. Diagnóstico producido por el parámetro máscara K2	195
Ilustración 4.19. Ejemplo 1 de diagnóstico producido por el sistema DDPC1.	203
Ilustración 4.20. Ejemplo 2 de diagnóstico producido por el sistema DDPC1.	205

VI

Ilustración 4.21. Ejemplo 3 de diagnóstico producido por el sistema DDPC1.	207
Ilustración 4.22. Ejemplo 1 de diagnóstico producido por el sistema DDPV1.	209
Ilustración 4.23. Ejemplo 2 de diagnóstico producido por el sistema DDPV1.	211
Ilustración 4.24. Ejemplo 3 de diagnóstico producido por el sistema DDPV1.	213
Ilustración 4.25. Ejemplo 1 de diagnóstico producido por el sistema DDPC2.	215
Ilustración 4.26. Ejemplo 2 de diagnóstico producido por el sistema DDPC2.	217
Ilustración 4.27. Ejemplo 3 de diagnóstico producido por el sistema DDPC2.	219
Ilustración 4.28. Ejemplo 1 de diagnóstico producido por el sistema DDPV2.	221
Ilustración 4.29. Ejemplo 2 de diagnóstico producido por el sistema DDPV2.	223
Ilustración 4.30. Ejemplo 3 de diagnóstico producido por el sistema DDPV2.	225

RESUMEN.

I. INTRODUCCION.

Las técnicas de análisis de texturas juegan un papel fundamental en muchos problemas de control de calidad industrial, ejemplos de ello los tenemos en que cada vez son más frecuentes los sistemas de inspección automática de materiales como plásticos, maderas, telas, etc, en los que el control se realiza mediante sistemas de visión artificial que inspeccionan los materiales empleando tales tipo de técnicas . Su uso normalmente se debe a que las superficies de los materiales que se utilizan en la industria presentan un aspecto visual homogéneo (texturados homogeneamente); de tal forma, que los defectos pueden aparecer de dos maneras:

- * Como desviaciones locales de la homogeneidad esperada.
- * Como apariciones de elementos ajenos a la propia textura (agujeros, raspaduras, manchas, etc).

Dependiendo del tipo de conocimiento que se tenga de los defectos existen dos metodologías para abordar el problema de la detección automática de defectos. Si se posee un conocimiento exacto sobre ellos entonces el proceso de detección consiste en la búsqueda de tales defectos, obviando el tratamiento de la textura del material a analizar. Desgraciadamente rara vez se produce este tipo de situación, teniendo entonces que utilizar técnicas de tratamiento de texturas.

A pesar de que existen distintos modelos matemáticos para el análisis de texturas (fundamentalmente de naturaleza estadística o estructural), el problema de la inspección visual automática mediante el tratamiento de texturas no ha sido resuelto de una forma general. Básicamente, los problemas de detección automática se pueden clasificar en

una primera aproximación en dos clases:

- Deterministas, que surgen cuando el material a analizar posee una textura modelizable mediante una función determinista, siendo el caso más representativo el de las texturas periódicas, en el que la detección se fundamenta en la localización de desviaciones de la periodicidad dada.
- No deterministas, que se plantean cuando las texturas se forman a partir de distribuciones aleatorias de los elementos que la constituyen, en este tipo de problemas el proceso de detección se fundamenta en la idea de que un defecto es una ruptura de la textura que presenta el material inspeccionado.

Es justo en el caso no determinista donde se ha desarrollado el trabajo realizado.

II. OBJETIVOS.

Partiendo de los conceptos y técnicas de la Visión Artificial y de la Teoría de Sistemas, el objetivo principal de esta tesis es el análisis y síntesis de un modelo formal general que sirva como base para el diseño de sistemas de inspección visual automática y su implementación y prueba en un caso real de detección de defectos en pieles. Para lograr esta meta se han tenido que cubrir los siguientes objetivos:

1. Estudio e implementación de técnicas de proceso de imágenes. Consiste, en primer lugar, en la búsqueda e implementación de las técnicas ya empleadas por los distintos métodos de inspección automática existentes, test, análisis y estudio de su bondad y en segundo lugar investigación y desarrollo de nuevas técnicas. Concretamente:

- Filtrados.
- Caracterización de texturas.
- Técnicas de clasificación.

Analizando su comportamiento en base a:

- Sensibilidad a presencia de defectos.
- Adaptabilidad a distintos materiales.
- Posibilidad de implementación mediante algoritmos rápidos.

2. Encaje teórico en el marco de la Teoría de Sistemas asistida por computador.

Este objetivo trata de la modelización de lo desarrollado en el punto anterior mediante conceptos y herramientas de la Teoría de Sistemas. Con la formulación de este modelo se ha realizado una formalización del proceso de detección visual de defectos, abarcando dicha formalización la especificación del espacio de entrada, estructuras de cómputo utilizadas y estructura del espacio de salida.

3. Diseño de prototipos de sistemas. Este objetivo es el responsable de la construcción de dos prototipos de sistemas de detección automática basados en los resultados obtenidos en las fases anteriores. En concreto se han diseñado dos prototipos de sistemas destinados a la inspección automática de dos materiales que presentan texturas diferentes: pieles de cerdo y de vaca.

III. ESTRUCTURACIÓN DE LA MEMORIA.

Esta memoria se estructura en cinco capítulos en los que se abordan los siguientes aspectos:

Capítulo 1º: Fundamentos y objetivos de la Visión Artificial y sistemas de inspección visual automática.

Capítulo 2º: Propuesta de metodología y estrategia para la detección automática de variaciones locales en texturas.

Capítulo 3ª: Técnicas de caracterización de texturas.

Capítulo 4º: Casuística, experimentación y prototipos.

Capítulo 5º: Aportaciones y conclusiones.

El capítulo primero está dedicado a situar el trabajo en su contexto. Para ello se empieza con la descripción de las ideas fundamentales de la Visión Artificial, abordando sus objetivos y el marco teórico actualmente más aceptado propuesto por David Marr [Marr 76], [Marr 82] . En segundo lugar, se abordan los fundamentos de los Sistemas de Inspección Visual Automáticos, acabando con una revisión histórica de tales tipos de sistemas. En este capítulo se pone de manifiesto que lo existente en la actualidad sobre la inspección automática dista mucho de ser un campo conceptualmente homogéneo en el seno de la Visión Artificial, constituyendo por el contrario un campo donde abundan soluciones específicas a problemas concretos.

En el capítulo segundo se describe la estrategia experimental seguida, el modelo teórico que se propone y una aplicación específica de dicho modelo. Inicialmente se formula una descripción general del problema de la inspección automática en Visión Artificial. Seguidamente se describe el modelo general que se plantea para el problema que nos ocupa, éste es novedoso pues no sigue el esquema computacional de pirámide invertida utilizado tradicionalmente en Visión Artificial. En el modelo planteado se

produce una expansión de un campo inicial de datos a un espacio de representación multicapa, describiendo cada capa una propiedad relevante del espacio de entrada, sobre el que se trabaja para producir el diagnóstico final. El concepto de homogeneidad juega un papel fundamental en nuestra propuesta, entendiéndose ésta como una respuesta uniforme producida por una regla genérica que mide una cierta propiedad relevante de la textura. En base a esta formalización del concepto de homogeneidad, se define el concepto de imperfección como una ruptura o desviación local significativa del grado de homogeneidad que presenta la textura en un área de la imagen, surgiendo así una característica importante del modelo; su naturaleza local. Por último, y en lo que al planteamiento del modelo se refiere, se describe una interpretación de este desde el punto de vista de la Visión Artificial. Esta interpretación establece que el proceso de detección de defectos se asocia a una segmentación en dos regiones (zona no defectuosa y zona defectuosa) en el que el criterio utilizado está basado en el cálculo del grado de similitud entre áreas locales situadas a una distancia dada. Esquemáticamente esta interpretación se define en base a las siguientes especificaciones:

1. Tipo de área local.
2. Conjunto de descriptores.
3. Relación de similitud.

En el marco de esta estrategia y para los materiales analizados, se han experimentado técnicas clásicas en Visión Artificial y se han desarrollado nuevas técnicas referentes a:

1. Preproceso de imágenes.

2. Caracterización de texturas.

3. Clasificación basada en funciones de distancia.

De las nuevas técnicas desarrolladas, caben destacar las referentes a preproceso, proceso facilitador y la destinada al establecimiento de las dimensiones del área local a utilizar en el proceso de detección. En cuanto a la primera, se trata de un proceso de naturaleza estadística que se comporta como un detector de flancos y que aplicado a las texturas analizadas produce una enfatización de los defectos, facilitando así su detección. Sobre la técnica desarrollada para el establecimiento del área local a utilizar, ésta se basa en un análisis de la estabilidad que presenta el grado de homogeneidad de una cierta propiedad de la textura ante una dimensión de área local variable.

El capítulo tercero está dedicado a la descripción de los distintos métodos de caracterización de texturas probados en la experimentación realizada. Concretamente se han utilizado descriptores tradicionales de texturas: estadísticos de primer y segundo orden, métricas entre histogramas y coeficientes de Fourier. También se han probado nuevas técnicas tales como: test χ^2 entre distribuciones, métricas entre distribuciones de segundo orden, respuesta ante núcleos lineales aprendidos y núcleos algorítmicos..

El capítulo cuarto está dedicado a ilustrar, en primer lugar, el comportamiento de algunos de los descriptores mencionados en el capítulo anterior, y en segundo lugar, el funcionamiento de los prototipos diseñados, que tienen como objeto la detección de defectos en los tipos de materiales que presentan texturas diferentes (pieles de cerdo y de vaca). Estos casos de materiales son ilustrativos pues presentan texturas diferentes que dan una idea de la generalidad de la estrategia propuesta y su funcionamiento. Por

8

último, se presentan dos variantes de los prototipos anteriores basadas ambas en el uso del proceso facilitador descrito en el capítulo segundo.

Finalmente, las aportaciones y conclusiones se presentan en el capítulo quinto.

CAPÍTULO 1.

Los Sistemas de Inspección Visual Automática.

1.1. FUNDAMENTOS DE LA VISIÓN ARTIFICIAL.

1.1.1. Objetivos.

La idea clave de la Visión Artificial es abordar el estudio de la visión como el conocimiento de los procesos de información que se necesitan para realizar inferencias sobre el mundo exterior a partir de una información visual inicial. A pesar de que la mayoría de los esfuerzos iniciales se han desarrollado para establecer formalmente qué problemas visuales son resolubles, esta concepción establece que en la resolución de cualquier problema de naturaleza visual no sólo debe contemplar todas aquellas especificaciones formales de dicha resolución, sino que también debe abarcar la descripción algorítmica y de implementación de los procesos necesarios para alcanzarla, independientemente de la naturaleza del sistema (natural o artificial) [Wides 90].

Generalmente se admite que el paradigma de la Inteligencia Artificial ayuda a establecer el conjunto de los problemas fundamentales de la visión, la razón de ello radica en que los orígenes y motivaciones de esta última están en la primera. Acorde con esta afirmación se encuentra el paralelismo existente entre los objetivos fundamentales de la Inteligencia Artificial y de la Visión Artificial, así se tiene que para esta última éstos consisten en:

1. Identificar y entender los principios de la visión (si se sustituye el término visión por inteligencia se tendría la primera motivación de la IA).
2. Desarrollar modelos que permitan a los sistemas asistidos por computador utilizar de forma útil información de naturaleza visual (que equivale a producir sistemas más inteligentes).

En cambio, es difícil definir de una manera precisa las finalidades fundamentales de la Visión Artificial debido a la heterogeneidad de facetas que ésta contempla. De hecho, una de las metas encuadrada en el primer objetivo enunciado consiste en determinar el significado de la visión. Marr la define como aquella actividad que permite a un sistema realizar representaciones útiles del mundo a partir de imágenes y que además no está cargada de información irrelevante [Marr 76]. A partir de esta definición surgen dos propiedades importantes sobre el proceso visual: la primera de ellas consiste en que éste es capaz de extraer información útil para los fines del sistema que lo soporta, y la segunda en que es capaz de seleccionar, y por lo tanto reducir, aquella información que le sea relevante.

Existen dos tendencias en Visión Artificial, la más antigua se basa en la suposición de que el proceso visual está determinado por la estructura del conocimiento, esquematizando dicho proceso por una secuencia de tres etapas: la primera consiste en el establecimiento de hipótesis a partir del conocimiento especializado, la segunda en la comprobación de las anteriores y la tercera en las posibles modificaciones de las primeras. Esta concepción del proceso visual tiene como exponentes destacados los trabajos realizados por el laboratorio de Inteligencia Artificial del Instituto Tecnológico de Massachusetts y por el Instituto de Investigación de Stanford.

La segunda tendencia, vigente en la actualidad, se fundamenta en la concepción de la visión como un proceso determinado por los datos obtenidos a partir de las imágenes de las escenas. Esta línea tiene su principal valedor en David Marr, quien postula que la caracterización de las formas de las escenas mediante representaciones antecede a la interacción con la estructura del conocimiento.

1.1.2. Un modelo para la Visión Artificial.

El modelo que se describe a continuación fue propuesto por Marr, [Marr 76], [Marr 77], [Marr 82], y más que un modelo formal se trata de una elegante estrategia sobre cómo abordar el estudio de la visión. Entre otros, esta propuesta tiene como antecedentes importantes los trabajos de Helmholtz [Helmholtz 25] sobre los fundamentos matemáticos y físicos de la visión, las aportaciones de Gibson [Gibson 50], [Gibson 79], sobre la importancia que tiene la estructura del mundo exterior en la percepción, y por último de Land y McCann [Land 71] y Horn [Horn 77], en sus aportaciones sobre iluminación y contornos respectivamente. Marr utilizó la idea de que hay que separar los procesos visuales de los sistemas que los llevan a cabo.

Entrando ya en detalles sobre el modelo, éste se fundamenta en las siguientes ideas básicas:

1. El proceso visual se define en base a los datos que se originan a partir de las imágenes de las escenas; de forma que toda restricción que se utilice se debe establecer en base a las propiedades físicas del mundo exterior y no a cualquier estructura de conocimiento establecida a priori.
2. En toda tarea visual se debe separar, por un lado, al proceso de información que la realiza y por otro, al sistema que lo lleva a cabo.

Desde un punto de vista estructural este modelo establece que para que una solución a un problema visual sea completa, ésta se debe expresar en tres niveles:

Nivel teórico: donde se especifican los problemas a resolver, las restricciones iniciales impuestas y las soluciones formales. En definitiva, y desde el punto de vista de la

Teoría de Sistemas, a este nivel le concierne la descripción formal de cómo conseguir una salida deseada a partir de unas entradas (imágenes); para ello se debe utilizar información útil a partir de propiedades físicas del mundo exterior. Para alcanzar este objetivo, en primer lugar, se deben desarrollar análisis que clarifiquen la estructura de los procesos de información visual independientemente de los sistemas que los realizan, este requerimiento es alcanzable en sistemas artificiales, en cambio, en sistemas naturales actualmente no lo es. En segundo lugar, se debe establecer cómo la estructura matemática y física de los dominios de los problemas afectan a la estructura del proceso que los resuelve.

Nivel Algorítmico: En este nivel se define el procedimiento que obtiene la solución deseada a partir de las especificaciones establecidas en el nivel anterior. Comprende también la representación de la información de entrada y de salida utilizada. Hay que observar que para unas especificaciones dadas a nivel teórico es posible establecer más de un procedimiento a este nivel. Por ejemplo, para unas especificaciones teóricas dadas acerca de la resolución de un problema, ésta se puede obtener bien por un procedimiento paralelo o bien por otro alternativo secuencial.

Nivel de Implementación: A este nivel le concierne la realización física del procedimiento algorítmico establecido en el nivel anterior.

Otro aspecto importante que aporta este modelo consiste en una propuesta de estructuración de la representación de la información visual, de forma resumida consiste en tres niveles o bocetos:

Boceto primario: las imágenes iniciales de las escenas se representan por propiedades del tipo: cambios, distribución y organización de intensidades. Para obtener esta información se utilizan primitivas tales como: cruces por cero, bordes y discontinuidades de estos.

Boceto secundario: partiendo del boceto anterior se representan propiedades del tipo: profundidad y orientaciones de las superficies. Para ello se hace uso de primitivas tales como: orientación local, distancias al observador, discontinuidades en la profundidad.

Boceto terciario: cuya finalidad es establecer un interpretación tridimensional de la escena, para ello se utilizan primitivas asociadas a elementos tridimensionales organizados jerárquicamente.

1.2. SISTEMAS DE VISIÓN PARA LA INSPECCIÓN AUTOMÁTICA

1.2.1. Fundamentos.

Una de las consecuencias del desarrollo de las nuevas tecnologías es la aparición de sistemas de visión aplicados al control de calidad de materiales industriales, a éstos se les denomina frecuentemente sistemas de inspección automática. Los objetivos principales de estos sistemas son por un lado, la mejora de la productividad en las cadenas de fabricación y por otro, sustituir al ser humano en aquellos entornos que no le sean saludables. Para lograr estos fines se deben cumplir los siguientes requerimientos:

Fiabilidad. Se han de incurrir en los diagnósticos unas tasas de error menores

que las producidas por expertos humanos.

Robustez. Estos sistemas deben ser capaces de trabajar en condiciones ambientales análogas a las que se dan en la planta de fabricación. Esta propiedad conviene tenerla en cuenta a la hora de valorar las distintas propuestas que aparecen en la bibliografía, pues en muchas ocasiones los resultados que se aportan se obtienen a partir de imágenes de laboratorio (adquiridas en condiciones ideales).

Tiempo de respuesta aceptable. El tiempo requerido para el diagnóstico automático debe ser asumible en la cadena de fabricación. Este requerimiento hace que muchas veces se tenga que acudir a soportes físicos muy potentes y de elevado coste económico.

En los últimos años se han propuesto distintos prototipos de sistemas de inspección automática que tratan de resolver problemas específicos utilizando una amplia variedad de técnicas de visión. Sin embargo, hay que decir que no existe ni un modelo formal y ni tan siquiera una propuesta de estrategia general para el diseño de tales sistemas. En cambio, lo que si se puede decir sobre las técnicas de visión empleadas es que caen dentro de la categoría de técnicas de bajo nivel que fundamentalmente tratan de resolver el problema mediante:

Análisis de contornos.

Que se ha aplicado en casos donde los defectos se presentan como elementos identificables ajenos al aspecto visual del material a analizar. Ejemplos de tales defectos son las raspaduras, agujeros, grietas, etc.

Análisis de texturas.

Se ha aplicado cuando se ha asumido que el aspecto visual del material a analizar presenta una textura uniforme. Se ha usado con más frecuencia que la categoría naterior, de ahí que merezca la pena que se expongan algunas conceptos básicos sobre estas técnicas. Se trata de un campo importante del proceso de imágenes, ya que para realizar un análisis de una escena el sistema visual humano a veces no sólo necesita información sobre los contornos y las formas de las regiones que estos delimitan, además también requiere información sobre las texturas, que dependen de la naturaleza de los objetos y sus posiciones relativas en la escena [Rao 93]. Incluso, cuando se pretende realizar una extracción de contornos y las regiones están poco contrastadas, se puede utilizar la información de texturas para tal fin.

A pesar de que el análisis de texturas se utiliza en un amplio abanico de tipos de imágenes, desde imágenes aéreas hasta microscópicas, no existe ni un modelo formal, ni tan siquiera una definición general aceptada sobre texturas. Una primera aproximación a la definición de textura podría ser la siguiente: *"Una textura es una superficie que presenta una impresión visual homogénea"*, una segunda definición más precisa y formal es la que establece que: *"Una textura es una imagen en la que la información significativa (visual y semántica) está presente en cualquier parte de dimensión suficiente"* [Unser 82]. Esta definición nos dice que la textura es una estructura redundante, en donde se involucran conceptos tales como: aspecto visual, significado semántico y aspectos espaciales, poniendo así de manifiesto la complejidad del concepto. Una tercera definición, aún más precisa y formal la establece Muñoz [Muñoz 87], que nos dice que *"una textura es un conjunto de primitivas tonales*

relacionadas espacialmente de forma estructural o funcional", estableciendo el autor dos niveles: Un primer nivel de primitivas tonales, y un segundo de organización espacial entre ellas.

El análisis de texturas se aborda utilizando dos modelos: modelo estadístico, y modelo estructural. El modelo estadístico se basa en utilizar para la caracterización propiedades estadísticas de los niveles de gris de la imagen (que en este modelo son las primitivas tonales) [Wang 90]. En cambio, el modelo estructural caracteriza una textura en base a la organización y relación existente entre las primitivas tonales. Teniendo en cuenta estas descripciones generales, podemos decir que el modelo estadístico es más general que el estructural; puesto que este último sólo es aplicable cuando se pueden extraer las primitivas tonales y las relaciones existentes entre ellas.

Acudiendo a la bibliografía se puede comprobar que en inspección visual automática la primera metodología se ha utilizado con más frecuencia que la primera. Esto es debido a que los autores han asumido el concepto de defecto como una ruptura de la apariencia visual del material sin valorar cuestiones referentes a las formas. Además, teniendo en cuenta las dimensiones de los defectos y la posible escasez de sus intensidades visuales, las estrategias globales han sido desechadas mayoritariamente, optándose, por tanto, por esquemas locales de proceso que consisten en dividir la imagen a analizar en áreas locales de tamaño fijo y de forma rectangular (llamadas generalmente ventanas) y procediendo posteriormente a caracterizar la texturas contenidas en ellas.

Se puede decir que la mayoría de los sistemas de visión de inspección automática propuestos se fundamentan en esquemas de clasificación elementales. Básicamente estos

esquemas consisten en establecer a priori una clase que representa al material no defectuoso, realizándose posteriormente el proceso de inspección consistente en detectar áreas en la imagen que se analiza que no pertenezcan a esta clase representativa. Mayoritariamente, los criterios seguidos para decidir si un área problema pertenece a la clase de referencia se fundamenta en funciones de distancia, utilizándose generalmente la distancia euclídea. Modelizada así la resolución del problema de detección, en gran medida su éxito dependerá:

- De la bondad de los criterios utilizados para seleccionar los patrones que darán lugar a la clase representativa del material no defectuoso. Sobre este factor hay que decir que en las distintas propuestas existentes en la bibliografía no se mencionan qué criterios se han utilizado.
- De los descriptores utilizados en la caracterización del material. Estos no sólo deben ser capaces de caracterizar al material a analizar, además deben ser sensibles a los defectos a detectar.

Desde un punto de vista funcional, frecuentemente los sistemas de visión de inspección automática adoptan una estructura análoga a la que se ilustra en la figura 1.1:




Figura 1.1. Estructura común de un sistema de visión de inspección automática

Acerca de cada una de estas etapas se puede decir lo siguiente:

Adquisición.

Esta etapa se soporta en los elementos físicos específicos de visión. Principalmente, estos elementos son: el elemento sensor utilizado y la interfase que permite la integración del elemento anterior en un sistema computador. Sobre estos elementos hay que decir, en el contexto de los sistemas de inspección automática, que habitualmente se utilizan cámaras de resoluciones dependientes del tipo de imagen a tratar. Sin embargo, en algunos casos se han utilizado scanners con el objeto de eliminar los efectos perturbadores que produce una iluminación no uniforme. En cuanto al segundo elemento, la interfase física de integración, en ocasiones es capaz además de realizar algunos procesos de imagen de forma autónoma. Esta etapa tiene por finalidad proporcionar las imágenes de entrada al resto del sistema.

Preproceso.

Se trata de una etapa cuya importancia depende de las condiciones ambientales de la etapa anterior y de la robustez de las etapas siguientes frente a fenómenos indeseables tales como ruidos e iluminaciones variables. Básicamente en los distintos sistemas que se han propuesto la etapa de preproceso tiene por objeto realizar alguna o algunas de las siguientes acciones:

1. Compensación de las posibles distorsiones que puedan existir en la adquisición, debidas al propio sistema y a la no homogeneidad en la iluminación.
2. Eliminación de elementos no relevantes existentes en la imagen de entrada y enfatización de elementos importantes.
3. Transformación de la imagen de entrada en otra de características más adecuadas para el diagnóstico.

Caracterización.

La finalidad de esta etapa es la de representar al material a analizar mediante un conjunto de descriptores. A dicho conjunto habitualmente se le denomina vector de descriptores o características. Formalmente, esta etapa se puede expresar como un proceso de representación en el que a cada elemento representado se le asocia un punto en un hiperplano de dimensión el número de características utilizadas, donde cada eje se asocia a una característica individual.

En cuanto al tipo de características utilizadas se ha empleado un amplio abanico, aunque se puede decir que fundamentalmente caen dentro de alguna de las siguientes categorías:

1. Descriptores obtenidos a partir de operadores de tipo lineal en forma de núcleos de convolución.
2. Descriptores basados en parámetros estadísticos de distintos órdenes. En esta categoría tenemos como ejemplos más representativos los histogramas y matrices de co-ocurrencia.

Clasificación.

En esta etapa se toma la decisión acerca de la calidad de cada área local problema. Como ya se ha mencionado, frecuentemente esta se basa en esquemas clásicos de clasificación entre dos clases, si se trata sólo de distinguir entre material defectuoso o no defectuoso, o bien entre más de dos si lo que se pretende es además distinguir tipos de defectos. Cuando no se tiene un conocimiento a priori de los defectos a detectar la regla de decisión se fundamenta en criterios probabilísticos.

1.2.2. Revisión histórica.

En este punto se van a describir una serie de propuestas de sistemas que nos describen el estado actual del problema que nos ocupa. Como se podrá comprobar todos poseen una estructura común en cuanto a los pasos a seguir, estructura presentada en la figura 1.1, en cambio difieren fundamentalmente en las técnicas de caracterización empleada debido a la diversidad de los materiales problema empleados. Es importante reseñar que estos sistemas han alcanzado un mayor desarrollo en el ámbito de la producción textil, debido fundamentalmente a las siguientes razones [Ade 83]:

* Se trata de un ambiente en el que los procesos de reconocimiento de formas están altamente estandarizados y los métodos a utilizar se pueden ajustar bastante al rango de productos a ser inspeccionados.

* En el caso de la inspección textil se cumple la importante restricción de que el producto a ser inspeccionado posee características constantes.

* No es un requerimiento esencial el determinar el área exacta donde se produce el defecto, sólo es necesario marcar la ocurrencia del defecto.

Seguidamente se describen por orden cronológico de aparición una serie de sistemas que aplican distintas técnicas en la detección de defectos. El criterio seguido para nombrar a cada una de estas propuestas es el título del artículo donde fueron hechas, ésto se ha hecho así debido a que sus autores no les han dado uno propio.

DETECCIÓN DE DEFECTOS MEDIANTE EL TRATAMIENTO DE TEXTURAS EN INSPECCIÓN AUTOMÁTICA [Unser 82].

Se trata de una propuesta que pretende ser una metodología general, según sus autores, para el problema de la detección de defectos. Funcionalmente la estrategia encaja perfectamente con el diagrama presentado en la figura 1.1 y conceptualmente esta metodología es de tipo local, tal y como se expuso en el punto anterior. Los autores parten del concepto de defecto como una desviación de la textura que presenta un área local de la imagen con respecto a una de referencia (aprendida) que representa al material considerado no defectuoso.

Para representar la textura del material a inspeccionar los autores proponen un

conjunto de descriptores, vectores de características, de naturaleza estadística obtenidos a partir del histograma de los niveles de gris, concretamente utilizan: media, desviación típica, correlaciones en distintas direcciones, contrastes en distintas direcciones y promedio de diferencias de niveles de gris en distintas direcciones. Por tanto, cada textura problema tendrá asociado un vector $V(x_i)$, siendo cada coordenada x_i el valor que adopta cada descriptor en la textura.

En cuanto al esquema de clasificación, los autores representan el material catalogado como no defectuoso mediante una clase W establecida a priori mediante un conjunto de muestras de material catalogado como no defectuoso. Esta clase, formada por una nube de puntos en el hiperplano de características, se representa mediante su centro de gravedad U , siendo las coordenadas de éste la media de los valores que adopta cada una de las características en cada punto perteneciente a la clase. Así, un área local problema, representada por el vector $V(x_i)$, se clasifica según la distancia que la separa de cada clase

"Si" $d_e(V,U) < U$ "Entonces"

Área local no defectuosa

"Si no"

Área local defectuosa

"Fin si"

Siendo $d_e(u,v)$ la distancia euclídea en un espacio de características normalizadas. Esto es:

$$D(V, U)^2 = \sum_{i=1}^m \frac{(V(x_i) - \mu_i^w)^2}{\sigma_i^w}$$

Siendo μ_i^w y σ_i^w la media y varianza respectivamente de la característica i -ésima de las muestras pertenecientes a la clase W . Los autores proponen que el umbral U sea calculado a partir de la probabilidad de cometer un error en el diagnóstico P_{fd} , que se obtiene a partir de la integral:

$$P_{fd} = \int_T^{\infty} P(D_w/w) dD_w$$

Siendo $P(D_w/W)$ la función de densidad de probabilidad condicional de la función de distancia empleada, evaluada en un amplio muestrario de texturas sin defectos.

APLICACIÓN DEL ANÁLISIS DE COMPONENTES PARA LA INSPECCION DE MATERIALES INDUSTRIALES [Ade 83].

El autor propone un método para la inspección de telas. La estructura normal de las telas se caracteriza por ser una micro-textura de dimensión 3×3 . El método se basa en la utilización de una transformación local de la imagen que da lugar a una caracterización "plana" que se utiliza junto a un clasificador.

El problema que pretende resolver este prototipo se puede plantear como sigue: se produce una superficie continua de tela de un cierto ancho y se hace pasar por una estación de observación a una velocidad constante. La superficie se debe inspeccionar sin interrupción y completamente, de forma que se deben detectar defectos de todo tipo,

pero no se exige la identificación de la naturaleza del defecto. Además, existe una textura casi regular para la que se define con una cierta tolerancia unas especificaciones "normales", cualquier desviación fuera de esa tolerancia se debe detectar en tiempo real.

La textura que presentaba el tejido a analizar estaba compuesta por hebras de hilo tanto en la dirección del movimiento de la tela como en sentido transversal, describiéndose en términos de distancias entre hebras, grosor del hilo y la forma en que se entrecruzaban las hebras. Los defectos más frecuentes eran: carencia de hebras, hebras dañadas, aumento o disminución de la distancia entre las hebras, aumento o disminución del grosor del hilo, manchas e irregularidades. Estos eran visibles con una luz transmitida a través de la superficie, otros eran más fácilmente observables con luz reflejada.

Entrando ya en la descripción del método utilizado, el autor intentó resolver el problema utilizando la Transformada de Fourier; puesto que la textura era casi periódica y los defectos en ella destruían su periodicidad. Sin embargo, las telas a menudo presentaban ondulaciones suaves que no eran detectables para el experto, y que aparecían en el espectro de Fourier resaltadas incluso a veces más que los defectos de interés. Ésto junto con la poca tolerancia de esta transformación a una iluminación no uniforme llevó al autor a desechar esta metodología.

La técnica empleada consistió en caracterizar cada área local en que la imagen a analizar era dividida, de dimensión 3x3, mediante un conjunto de 9 descriptores, vector de descriptores, cada descriptor era la respuesta del área al convolucionarla ante un núcleo lineal específico que el autor definió basándose en las características de su

textura problema, por tanto fueron 9 los núcleos propuestos por el autor siendo cada uno de ellos sensible a unos fenómenos específicos en la imagen. Finalmente, la clasificación se realizaba mediante umbralizado de forma que cada descriptor, convolución ante un núcleo dado, tenía asociado un umbral específico.

UN PROTOTIPO DE SISTEMA PARA LA LOCALIZACIÓN E IDENTIFICACIÓN DE DEFECTOS EN MADERA [Connors 83].

Se trata de un sistema aplicable en entornos industriales de fabricación de muebles. Esta propuesta es interesante debido a que pretende solucionar también el problema de la identificación de defectos. La metodología en la que se fundamenta consiste en dividir la imagen a inspeccionar en ventanas cuadradas y calcular en cada una de ellas un conjunto de descriptores de naturaleza estadística. El proceso de clasificación se divide en dos etapas, en la primera se decide si un área problema es buena o defectuosa y en el caso de que se catalogue como defectuosa, la segunda parte del clasificador decide sobre el tipo de defecto que presenta.

El problema a resolver por este prototipo se puede describir de la siguiente manera: en una cadena de fabricación de muebles los tablones de madera a utilizar se hacen pasar secuencialmente por delante de un sistema de adquisición de imágenes, para cada tablón y de cada cara, se toma un conjunto de imágenes. Una vez adquiridas las imágenes de la madera a inspeccionar, se procede a detectar sus posibles defectos y en el caso de que los hubiera, se identifican sus tipos. Una vez que se ha construido un mapa de defectos y tipos en cada superficie de la madera, se procede al corte automático de forma que, dependiendo del tipo de defecto que presente, cada trozo

resultante del corte se destinará al montaje de un determinado tipo de mueble.

Describiendo ya la metodología seguida, hay que decir que inicialmente se divide la imagen a analizar en ventanas cuadradas de 8x8 disjuntas. En cuanto a la caracterización de cada ventana, ésta se hace utilizando descriptores estadísticos, distinguiéndose entre los destinados al proceso de detección de defectos y entre los destinados al proceso posterior de identificación del tipo de defecto. Concretamente los utilizados son, para el proceso de detección, media, varianza, curtosis y apuntamiento, y para el proceso de identificación, parámetros obtenidos a partir de matrices de co-ocurrencia, siendo los empleados: inercia, homogeneidad local, energía, entropía, prominencia de agrupamiento y grado de agrupamiento.

En cuanto al esquema de clasificación empleado, hay que decir que los autores asumen que madera no defectuosa se comporta según una distribución $f(v) = N(\mu, \Sigma)$, siendo μ el vector media de características y Σ la matriz de covarianzas. Para decidir sobre la calidad del material se utiliza la distancia de Mahalanobis:

$$(v-\mu)^t \Sigma^{-1} (v-\mu) \leq U$$

Para la identificación de defectos se utiliza un clasificador multiclase por pares. Para ello se utiliza como descriptores los estadísticos de segundo orden anteriormente citados, de forma que se realizan $k(k-1)/2$ decisiones para cada área problema defectuosa a catalogar, siendo k el número de tipos de defectos definidos. Cada decisión se establece entre pares de defectos y se utiliza el método de Bayes, asumiendo equiprobabilidad en la aparición de cada defecto y siendo la función de densidad de probabilidad condicional asociada a cada caso de defecto de tipo Normal.

SISTEMA PARA LA DETECCIÓN DE DEFECTOS EN SUPERFICIES DE NEUMÁTICOS [Borghesi 84].

Se trata de un prototipo de sistema dedicado al control de calidad de productos fabricados, concretamente se trata de neumáticos. Las imágenes tratadas son de Rayos X y la metodología de detección se basa en el uso de matrices de co-ocurrencia. Esta propuesta tiene el interés de que son las propias matrices de co-ocurrencia y no los parámetros obtenidos a partir de ellas, los descriptores utilizados.

El problema a resolver por este sistema se puede describir de la siguiente manera: Los neumáticos fabricados se pasan por delante de una cámara de rayos X, que realiza distintas tomas desde distintos ángulos del neumático a inspeccionar, con cada imagen se procede a analizar la estructura de la superficie del neumático, teniendo en cuenta que en un neumático sin defectos su superficie presenta un dibujo con unas características geométricas bien definidas, en base a líneas en distintas direcciones, los defectos que se pueden presentar son líneas incompletas, carencia de líneas, líneas en direcciones incorrectas y presencia de elementos metálicos en la superficie del neumático. Si el proceso de inspección detectaba algún fallo el sistema debía disparar una alarma para que una persona marcara manualmente el fallo detectado.

La metodología seguida por este sistema se basa en un esquema de proceso local de imagen, que consiste en dividir la imagen a analizar en regiones cuadradas de dimensión entre 5 y 6 veces el ancho de las líneas utilizadas para definir el dibujo del neumático. En cuanto a la caracterización empleada se han utilizado matrices de co-ocurrencia calculadas en cada área local problema. En cuanto a la regla de decisión empleada para producir el diagnóstico, ésta se basa en la formas que adoptan las

matrices de co-ocurrencia debido a que cuando el neumático es correcto éstas presentan una forma diagonal, en cambio cuando se da algún defecto, esta forma se rompe.

SISTEMA DE DETECCIÓN DE DEFECTOS EN CABEZAS DE DISCOS MAGNÉTICOS [Fong 84].

Es una propuesta de metodología para la detección de cabezas de discos magnéticos defectuosas. El interés de la propuesta radica en la sencillez del método, pues se basa en formas del histograma.

El problema que se plantea se describe de la siguiente manera: Las cabezas de disco están compuestas de un material formado por dos tipos de partículas, que los autores referencian como de tipo A y B, las de tipo A debido a su alta reflectancia aparecen en la imagen con mucho brillo, en cambio las de tipo B aparecen como elementos oscuros en la imagen. Cuando la cabeza está correctamente fabricada ésta posee un aspecto de textura granulada muy fina, teniendo un histograma que posee un sólo nódulo. En cambio, en las cabezas defectuosas se ponen de manifiesto altas concentraciones de partículas de un determinado tipo en áreas locales de la imagen, rompiendo el aspecto natural del material y dando lugar a un histograma bimodal en las zonas que contengan defectos.

El método empleado para el diagnóstico se basa en analizar todas las ventanas de dimensión 5x5 que se pueden definir en la imagen a analizar. Este análisis consiste simplemente en comprobar si el histograma asociado al área problema posee una forma bimodal, si es así, entonces se trata de una región en la que se produce un defecto y su localización se efectúa mediante umbralizado, calculándose el umbral a partir del

propio histograma.

SISTEMA DE INSPECCIÓN AUTOMÁTICA DE PASTILLAS DE FRENO [Roning 86].

Se trata de una propuesta metodológica cuyo interés radica en la diversidad de técnicas de visión empleadas. Básicamente, se describen un conjunto de tipos de defectos y se propone para cada uno una técnica de detección. Concretamente se plantean los siguientes tipos y técnicas de detección asociadas:

Defecto tipo 1: Éste se produce cuando el área de contacto de la pastilla de freno posee unas dimensiones inferiores a lo tolerable, para su detección se utilizan imágenes binarias y ésta se establece en base a una comparación del perímetro obtenido en la imagen problema con respecto a unos patrones de referencia. Para obtener el perímetro se utiliza un algoritmo de conectividad.

Defecto tipo 2: Se trata de un tipo de defecto más sutil que el anterior; debido a ello se utilizan imágenes de niveles de gris. El aspecto visual que presenta este tipo de defecto es una zona de la superficie de la pastilla con una textura distinta a la que posee la zona no defectuosa. Este tipo de defecto produce también una disminución significativa del área de contacto efectiva de la pastilla. El método que los autores proponen se fundamenta en un proceso de discriminación de texturas a partir de histogramas de niveles de gris obtenidos localmente. Concretamente la característica utilizada es el ancho del histograma, puesto que en zonas defectuosas este es considerablemente mayor al que presentan las zonas no defectuosas.

Defecto tipo 3: Este tipo se presenta cuando en la superficie de la pastilla, y más

concretamente cerca de sus bordes, existen raspaduras. Para su detección se utilizan dos procesos en cadena, el primero consiste en un suavizado para eliminar espúreos y el segundo en una detección de contornos.

Defecto tipo 4: Éste se da cuando la superficie de la pastilla presenta una textura porosa. Para su detección se utiliza la Transformada de Fourier, concretamente se utiliza como descriptor la energía de ciertas bandas del espectro, puesto que en las zonas en donde se da este tipo de defecto, el descriptor toma unos valores mayores a los que posee cuando se calcula en una zona no defectuosa.

ESTUDIO DE DIFERENTES DESCRIPTORES DE NATURALEZA ESTADÍSTICA PARA LA CARACTERIZACIÓN DE TEXTURAS DE ALFOMBRAS [Siew 88].

En este trabajo los autores hacen un estudio acerca de la idoneidad de distintas técnicas de naturaleza estadística en la caracterización de texturas que presentan distintos tipos de alfombras. Concretamente, las técnicas empleadas son las siguientes:

- * **Matrices de co-ocurrencia.** Para esta metodología de caracterización de texturas se han utilizado los siguientes descriptores: energía, entropía, inercia, homogeneidad local y correlación.
- * **Distribución de diferencias de niveles de gris.** Se utiliza para este tipo de distribución los descriptores siguientes: contraste, momento angular de segundo orden, entropía y media.
- * **Matrices de trayectorias de niveles de gris.** En este caso se utilizan parámetros que miden las siguientes propiedades de la distribución: tendencia a trayectorias de longitud larga, tendencia a trayectorias de longitud corta, grado

de uniformidad de los niveles de gris, grado de uniformidad en las longitudes de las trayectorias y porcentaje de trayectorias existentes en relación con el número de pixels de la imagen.

*** Distribuciones de diferencias de niveles de gris de pixels vecinos.** Al igual que en la metodología anterior aquí se calculan distintos parámetros que miden ciertas propiedades de la distribución: tendencia a frecuencias pequeñas, tendencia a frecuencias altas, entropía, grado de uniformidad y segundo momento angular.

En base a las experiencias realizadas, los autores llegan a las siguientes conclusiones:

- Para cada tipo de alfombra, el comportamiento de cada descriptor varía en función del grado de grosor que presenta la textura asociada a cada tipo.
- Para las cuatro metodologías fue la última la que mejor comportamiento tuvo.
- Para una misma técnica, existía un alto nivel de correlación (coeficiente 0.99) entre distintos descriptores.

SEGMENTACIÓN DE DEFECTOS EN LA INDUSTRIA TEXTIL [Neubauer 92].

En este trabajo se propone un prototipo de sistema de inspección automática para la detección de defectos en productos textiles. La estrategia se basa en el uso de núcleos de convolución sensibles a ciertas propiedades topológicas, en el uso de histogramas de las imágenes convolucionadas como descriptores y en el uso de una red Perceptron como clasificador.

El problema que el prototipo de sistema propuesto ha de resolver consiste en la detección de distintos tipos de defectos que pueden poseer los productos elaborados en una planta de fabricación textil. El origen de los defectos puede ser o un fallo en el proceso de tejido del material, o cualquier defecto que pueda presentar el material utilizado en la confección de los productos. El sistema debe ser capaz de procesar de 100 a 180 metros de tejido por minuto.

Para alcanzar su objetivo, el sistema ejecuta una secuencia de procesos que consiste en: preproceso, convoluciones, caracterización y clasificación. Seguidamente se describe de una forma general cada una de estas etapas.

Preproceso. Dos son los objetivos de esta etapa: la primera es lograr inmunidad a cambios de iluminación y la segunda es transformar la imagen problema en un conjunto de imágenes que faciliten el diagnóstico. Para alcanzar el primer objetivo, el sistema lleva a cabo una transformación algorítmica inspirada en trabajos previos sobre la visión humana. Para lograr el segundo objetivo, la imagen resultado de esta transformación se convoluciona con tres núcleos separables obteniéndose tres imágenes transformadas, más apropiadas para el diagnóstico utilizado. La dimensiones de los núcleos empleados son de 5x5 y son sensibles a ciertas propiedades topológicas que se dan cuando en la imagen problema existen defectos.

Caracterización. Esta etapa consiste, en primer lugar, en dividir las imágenes resultado obtenidas de las convoluciones realizadas en la etapa anterior en áreas locales disjuntas de forma cuadrada y de dimensiones de 10x10. Seguidamente, cada área se representa por su histograma de niveles de gris, en este paso se reduce a 8 niveles la escala de niveles de gris.

Clasificación. El proceso de detección se realiza mediante una red Perceptron, el autor justifica el uso de este método de clasificación debido a que se trata de un esquema que permite el aprendizaje supervisado y que produce unos resultados análogos a otros clasificadores tradicionales.

CAPÍTULO 2.

Metodología y Estrategia General para la Inspección Visual Automática mediante la detección de cambios de texturas.

2.1. PARADIGMA.

2.1.1. Introducción.

El problema de la detección de defectos aparece en muchos procesos de fabricación industrial como un aspecto del control de calidad del producto, por lo que es un problema importante en la automatización de las cadenas de producción. Esto justifica el esfuerzo que se ha realizado y se ha de realizar en el futuro para su solución.

En los últimos años las técnicas de Visión Artificial aplicadas a procesos robóticos han desarrollado procedimientos para reconocer piezas en escenas más o menos complejas. Estos se basan en representaciones mediante características que describen sus formas y propiedades. Si consideramos un defecto como un objeto aislado en un fondo que presenta una cierta uniformidad, no es descabellado pensar que las herramientas de Visión Artificial pueden ayudarnos a encontrar una solución al problema de detección de fallos. Por ello el primer paso consiste en establecer un marco teórico de trabajo donde poder plantear y formalizar el problema que nos ocupa. Para ello, lo primero es encontrar una respuesta a la pregunta ¿cómo se define un defecto?, su respuesta no es obvia si se quiere ser preciso, ya que al igual que otros muchos problemas de visión no tiene una fácil formalización.

Al observar las imágenes producidas por ciertas superficies de materiales industriales con imperfecciones, éstas presentan un fondo que se caracteriza por tener una textura con una cierta uniformidad o periodicidad. En cuanto a los defectos, tales como: agujeros, manchas, rasgaduras, etc .. , producen una ruptura en la uniformidad

o periodicidad mencionada. El grado de uniformidad o periodicidad de las texturas, así como la mayor o menor perturbación de estas propiedades producidas por las imperfecciones, son los aspectos que influyen en la complejidad de la solución al problema. Con este planteamiento, el problema de la detección de defectos se transforma en un problema de detección de cambios de uniformidad o periodicidad de texturas.

Partiendo de la hipótesis anterior, la solución al problema consiste en encontrar un conjunto de propiedades que caractericen la uniformidad de la textura y que sea sensible y cambie de forma apreciable en las zonas defectuosas o no homogéneas. En este punto surge una segunda pregunta ¿cual es el conjunto óptimo de descriptores que caracterizan una textura?. La respuesta a esta cuestión no es trivial puesto que la propia definición de textura es borrosa y posiblemente cada problema tenga un conjunto de descriptores óptimos distinto.

Después de una revisión de los distintos métodos de caracterización de texturas aplicados en problemas de inspección visual automática y nuestra experiencia en el campo de la Visión Artificial nos atrevemos a proponer una metodología para encontrar una solución al problema de la detección de defectos [Candela 92A]. Esta metodología, desde el punto de vista de la Teoría de Sistemas y de la Teoría de Sistemas asistida por computador, tal y como apunta Pichler [Pichler 88], se puede estructurar vertical y horizontalmente.

Descripción del problema.

El objetivo que se plantea es poder detectar defectos en materiales a partir de

imágenes digitalizadas adquiridas mediante un sistema cámara-computador. Basándonos en un caso específico de material, consistente en pieles naturales (cerdo y vaca), se observa lo siguiente acerca de la apariencia visual de la zonas defectuosas:

1. Los fallos se manifiestan como cambios estructurales o como cambios tonales.
2. Para un mismo tipo de defecto, la intensidad del cambio estructural o tonal con respecto a la zonas no defectuosas del material no es siempre la misma.
3. Incluso en muestras de material no defectuoso se pueden producir variaciones tonales y estructurales muy suaves.

Dadas estas observaciones, la detección de defectos se puede modelizar mediante procesos que permitan detectar cambios sutiles en la texturas de los materiales problema. El establecimiento del conjunto óptimo de descriptores que permite distinguir y discriminar las zonas defectuosas y no defectuosas del material no es tarea fácil y conlleva la realización de procesos de distinta naturaleza para obtener una solución satisfactoria al problema planteado.

2.1.2. Marco general.

Cuando nos enfrentamos al problema de la detección de defectos en materiales específicos, como por ejemplo los defectos en pieles que se manifiestan como variaciones sutiles en la textura, se concluyó, después de una serie de trabajos experimentales, que si bien para ciertos tipos de materiales descritos en la literatura bastaba un esquema computacional visual donde en ningún momento se aumentaban los

grados de libertad, sino que al contrario, se disminuían según la típica pirámide invertida, para los casos que nos interesaban los resultados eran muy pobres. De hecho, ni siquiera los conceptos sobre Teoría de Sistemas propuestos por Mira y otros [Mira 84] basados en un único bloque conceptual serían aplicables, sino que al menos se necesitarían una serie de ellos. Aún haciendo abstracción del tiempo, puesto que en nuestro caso no utilizamos imágenes dinámicas, el esquema conceptual citado debería modificarse de tal forma que sobre el campo de datos inicial se han de realizar múltiples transformaciones coexistentes para generar un espacio de salida multicapa. Incluso, parece necesario que la decisión final se tome sobre un nuevo espacio multicapa de entrada, siendo cada uno de ellos representativo de los resultados de una decisión tomada sobre el espacio multicapa del espacio de salida de la estructura anterior, tal y como se representa en la siguiente figura:




Figura 2.1. Modelo general

En la evolución del trabajo, la necesidad de irse a este tipo de espacio de representación fue el resultado de una metodología que se muestra en la figura 2.2:

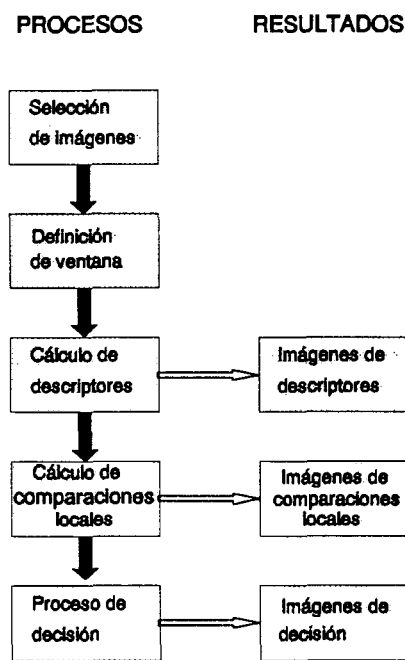


Figura 2.2. Estrategia general

Esta metodología y sobre todo su posterior incorporación al sistema propuesto y experimentado en este trabajo, sigue la línea genérica de la primera parte del llamado "Programa II de McCulloch para lo Artificial" según ha sido recientemente realizado por Rovaris [Rovaris 92]. Esto es, se intentó especificar en pasos lo que un observador natural podía concluir después de la experimentación diversa con imágenes, utilizando tanto técnicas ya existentes como otras desarrolladas por nosotros en una primera etapa y continuando con el mismo método para las etapas sucesivas. Así en la figura 2.3 se muestran los procesos que forman el sistema final que aquí se propone, que de una forma sintetizada se pueden describir de esta manera: a partir de la selección de imagen, se establecen los tamaños de actuación de las zonas relativamente locales,

seguidamente se procede al cálculo de descriptores para así generar una serie de imágenes (imágenes de descriptores). Se observan estas imágenes para de nuevo definir los tamaños y las formas de las zonas donde aplicar criterios diferenciales, para generar a su vez un conjunto de imágenes de comparaciones locales, en regiones tipo centro-periferia, y de nuevo, por observación, se pasa a un espacio de diagnósticos primarios a partir del cual y con una regla de decisión adecuada se obtiene una única imagen de diagnóstico final.

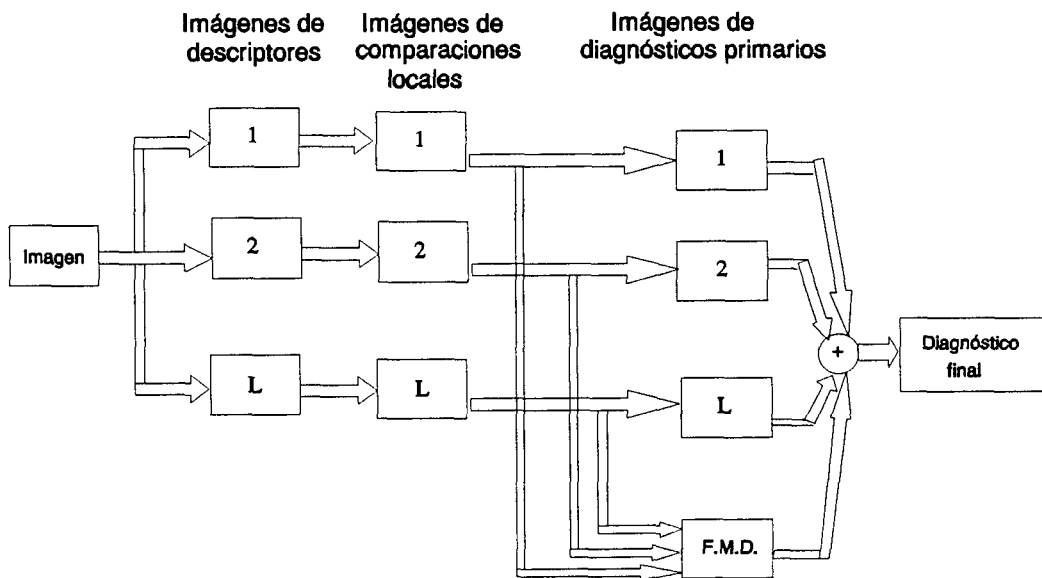


Figura 2.3 . Esquema de procesos.

Para representar estos procesos se va a utilizar una formulación basada en la propuesta de Moreno [Moreno 78], [Moreno 91]. Para representar el espacio de entrada [I] se va a utilizar la nomenclatura $I(i,j,\dots,n)$, siendo (i,j,\dots,n) la n-tupla que determina cada dato del espacio [I]. Análogamente, el espacio de salida [F] se representa por

$F(i', j', \dots, n')$.

Un proceso sobre $I(i, j, \dots, n)$ es un conjunto de reglas $R(i, j, \dots, n)$, una regla para cada una de las posibles tuplas (i, j, \dots, n) , tal que aplicada a los valores $I(i, j, \dots, n)$ produce un nuevo espacio $F(i', j', \dots, n')$. Esto es:

$$F(i', j', \dots, n') = R(i, j, \dots, n) [I(i, j, \dots, n)]$$

Por tanto, cuando los espacios de entrada y salida estén configurados por imágenes se tendrá que todo proceso de imagen se representará mediante la expresión:

$$F(y', x', t') = R(y, x, t) [I(y, x, t)]$$

Si además se asume independencia temporal, la expresión anterior se reduce a:

$$F(y', x') = R(y, x) [I(y, x)]$$

En el marco del esquema computacional planteado se presenta una formalización de los sistemas de inspección visual basada en la noción de defecto como una variación local significativa de la homogeneidad que presenta una cierta propiedad del espacio de entrada $I(y, x)$.

2.1.3. Formulación del modelo.

A continuación describimos el modelo que proponemos para modelizar los sistemas de inspección visual automáticos. Para ello tomaremos como referencia la figura 2.1 mostrada anteriormente.

Construcción del espacio de representación múltiple.

La primera etapa consiste en la construcción del espacio de representación



múltiple. Dicho espacio de representación está formado por un conjunto de imágenes de descriptores, describiendo cada una de ellas una propiedad relevante de la imagen $I(y,x)$. Por tanto, cada imagen de descriptores sigue la expresión general:

$$C(\hat{y}, \hat{x}) = R(y, x) [I(y, x)]$$

Al conjunto de imágenes que forman el espacio de representación lo denotaremos por $\{C(\hat{y}, \hat{x})\}$ que espacialmente se interpreta como un volumen cúbico de representación en donde cada plano de dicho volumen está asociada a una característica. Para describir detalladamente como se lleva a cabo esta expansión de representación, donde pasamos de un espacio de entrada bidimensional a otro de mayor dimensión, se debe enunciar lo que llamamos la restricción de dimensión mínima de subimagen y que se expresa de la siguiente manera: sea $R(y,x)$ una regla que evalúa una cierta propiedad de $I(y,x)$ entonces se define la unidad mínima de área de trabajo local, que por simplificar asumimos cuadrada, como aquella de dimensión D a partir de la cual la descripción evaluada por $R(y,x)$ es válida, a dicha subimagen la denotaremos por W . Por lo tanto, toda caracterización o descripción evaluada por $R(y,x)$ sólo se podrá realizar a partir de subimágenes de dimensión igual o mayor que D .

Definición: Una partición $P(W,d)$ se define como una operación que aplicada al dominio espacial y,x de la imagen de entrada, genera el conjunto formado por todas las subimágenes del tipo W , que se expresará como $\{W\}$, tal que la distancia mínima que puede haber entre cualquier par de ellas pertenecientes a dicho conjunto es d , esto es:

$$dist_e(Q(y, x), Z(y, x)) = K, K \leq d \forall Q(y, x), Z(y, x) \in \{W\}$$

Asumiendo que la distancia que separa a dos subimágenes es igual a la distancia euclídea existente entre los puntos centrales de cada subimagen. Por tanto, teniendo en cuenta la restricción de dimensión mínima de subimagen y el concepto de operación de partición, la expresión que formulaba de una forma general un proceso de caracterización de una imagen de entrada $I(y,x)$ en nuestro esquema se reescribe como:

$$C(y', x') = R(y, x) [Z(y, x)], Z(y, x) \in \{W\}$$

Que significa que una caracterización $C(y', x')$ de $I(y,x)$ es el resultado de aplicar a cada elemento del conjunto $\{W\}$, que son áreas de trabajo locales del espacio de entrada, el conjunto de reglas $R(y,x)$.

El espacio de comparaciones locales.

La segunda etapa de nuestro modelo consiste en lo que hemos denominado espacio de comparaciones locales. Dicho espacio se obtiene al aplicar sobre cada imagen de descriptores del espacio de representación múltiple una regla $R(y,x)$ consistente en un operador algorítmico ON-OFF de inhibición lateral, con el objeto de medir el grado de uniformidad que presenta una descripción $C(y,x)$, dando lugar a un conjunto de imágenes de comparaciones, $\{D_{g',y',x'}\}$, una por cada imagen de descriptores, por tanto el cálculo de cada imagen en el espacio de comparaciones locales se formula:

$$D(y', x') = R(y, x) [C(y, x)]$$

Específicamente, las comparaciones locales se establecen entre regiones del tipo

centro-periferia, asumiéndose el concepto de centro-periferia de la manera que se expresa seguidamente. Dada una imagen de descripción $C(y,x)$ definimos una relación de binaria T^K entre pares de elementos de $C(y,x)$ como:

$$C(y_0, x_0) T^K C(y_1, x_1) \Leftrightarrow \text{dist}_e(C(y_0, x_0), C(y_1, x_1)) = K, C(y_0, x_0), C(y_1, x_1) \in \{$$

Siendo K la distancia euclídea que separa a ambos puntos en la imagen de descripción. Al conjunto de elementos que cumplen T^K con respecto a $C(y_0, x_0)$ lo llamamos periferia de dicho punto.

Los diagnósticos en nuestro modelo se ubican en dos niveles, en un primer nivel se encuentra el espacio de diagnósticos primarios, que se obtienen a partir del nivel anterior, espacio de comparaciones locales, utilizando reglas de decisión que producen una salida binaria (0,1). El segundo nivel de diagnóstico constituye la salida final de nuestro modelo, éste se obtiene computando una regla de naturaleza lógica aplicada en volúmenes del espacio de diagnósticos primarios.

2.1.4. Interpretación del modelo planteado.

El modelo planteado formaliza la detección de defectos como un proceso de segmentación de la imagen problema en regiones de dos tipos. El criterio de segmentación utilizado se establece a través de las reglas utilizadas para medir el grado de homogeneidad que presenta una cierta propiedad de la imagen de entrada. Esto conduce a un esquema de segmentación por detección de cambios significativos en la propiedad evaluada por $R(y,x)$ (detección de flancos) en el espacio de salida $F(y',x')$, por lo tanto se detectan los bordes de las regiones.

La relación binaria T^K define la continuidad del descriptor; a medida que la distancia K usada en T^K aumenta, el proceso de comparación se aplica a áreas más alejadas y por tanto con un menor grado de solapamiento entre regiones. Por consiguiente, a mayor distancia establecida en T^K , menor continuidad en la descripción $F(y',x')$.

En la operación $P(W,d)$, que produce un conjunto de subimágenes $\{W\}$, el parámetro d representa el grado de resolución del proceso de representación producida por $R(y,x)$. Para subimágenes rectangulares, la resolución máxima se establece cuando se obtienen todas las regiones posibles de dimensiones w_y*w_x , dando lugar a un espacio de salida $F(y',x')$ de dimensión $(L_y-w_y+1)*(L_x-w_x+1)$, siendo L_y y L_x las dimensiones verticales y horizontales respectivamente de la imagen de entrada. En el caso opuesto, para un mismo tipo de imágenes, la menor resolución se obtiene al aplicar una subdivisión que consiste en obtener todas las subimágenes posibles de dimensión w_y*w_x sin solapamiento, este proceso da lugar a una imagen de descripción de dimensión $(L_y/w_y)*(L_x/w_x)$.

En cuanto a la evaluación del grado de similaridad, ésta se define en función de los valores adoptados por los distintos descriptores. Esta evaluación se puede realizar mediante criterios heurísticos, o bien, puede adoptar formas teóricas más evolucionadas, por ejemplo, cuando se define en base a métricas, estableciendo la relación de similaridad en base a criterios de distancia.

Por último decir que cualquier implementación del modelo debe contemplar los siguientes aspectos:

1. Partición del espacio de entrada $I(y,x)$: en este punto se establece cómo se

obtiene el conjunto de subimágenes W . Por tanto se define en base a:

- El tipo de área local.
 - Las dimensiones.
 - La resolución de la partición.
2. Conjunto de propiedades a evaluar.
 3. Distancia entre regiones utilizada para medir su homogeneidad.
 4. Operador de homogeneidad utilizado.

2.2. MARCO ESPECÍFICO.

En este apartado describimos el método seguido para la detección de defectos en pieles, a éste se ha llegado tras la realización de distintas pruebas [Muñoz 94]. Esta metodología presenta la ventaja de ser independiente del tipo de material y del defecto, por lo que es susceptible de ser utilizada en la detección de defectos de materiales tales como: plásticos, tejidos, madera, etc. Nuestra propuesta de esquema está formado por las siguientes etapas:

2.2.1. Construcción de la muestra significativa.

El objetivo de esta etapa es el de disponer de un conjunto de imágenes que revelen las propiedades significativas tanto del material a analizar, como la de los defectos a detectar. Para obtener estas imágenes se deberán tener en cuenta los siguientes aspectos críticos:

1. Condiciones de iluminación que permitan que se pongan de manifiesto las propiedades del material y de los defectos y que además sean asumibles en el

entorno donde debe operar el sistema a diseñar.

2. Utilizar una resolución de imagen apropiada, ésta depende tanto de la naturaleza del material como de los defectos a localizar.

Las muestras del material a analizar deben ser proporcionadas por expertos en el control de calidad del material.

Iluminación.

Desde un principio se puso de manifiesto que el tipo de iluminación empleada en la adquisición de las imágenes afectaba de forma crítica a la claridad (entendiéndose como la facultad de percepción visual) con que se manifestaban tanto las texturas de los materiales inspeccionados como los defectos que estos presentan. Con el fin de determinar el tipo de iluminación más adecuada para el problema planteado, se probaron distintos tipos que básicamente se caracterizan por:

- * La fuente de luz.
- * El tipo de proyector.
- * Dirección del haz de luz.

Tipo de fuente de luz.

Se experimentó con tres tipos: fluorescente, lámparas de tungsteno y lámparas halógenas. De las pruebas realizadas se concluyó que era la última la más apropiada pues producía un haz más concentrado y de mayor potencia que las dos restantes.

Tipo de proyector.

Se probaron dos tipos: los que proporcionan una luz suave (difusa) y los que proporcionan una luz concentrada (dura). Se comprobó que con el segundo tipo de iluminación se revelan mejor las texturas de los materiales.

Dirección del haz de luz.

Se experimentó con tres tipos: luz frontal, contraluz y luz rasante. Se puso de manifiesto que con la luz frontal la texturas tienden a ser eliminadas, con la iluminación a contraluz el efecto anterior aumenta, en cambio, con la iluminación rasante tanto las texturas como las imperfecciones aparecen de una manera más clara.

Por consiguiente se utilizó un sistema de iluminación que consistía básicamente en un foco halógeno de 1000 W de potencia que proyectaba una luz dura rasante sobre la muestra a adquirir; por tanto las imágenes utilizadas en la experimentación no han sido producidas en condiciones de iluminación especiales (imágenes de laboratorio).

Especificaciones de las imágenes.

Las imágenes utilizadas poseen una dimensión vertical de 512 puntos y horizontal de 768. Los puntos de imagen son cuadrados; no existiendo por tanto fenómeno de homotecia. La resolución utilizada en la adquisición es de 4 puntos de imagen por mm². Por último decir que la escala discreta de niveles de gris utilizada es de 256 niveles.

2.2.2. Mejora de la imagen a analizar.

En este apartado se describen las técnicas empleadas en el preproceso con el fin de transformar las imágenes originales, adquiridas en condiciones ambientales, en imágenes más óptimas para la fase de detección [Candela 92B]. Específicamente, se trata de conseguir una imagen en la que la detección de defectos:

1. Sea más sencilla de llevar a cabo en lo que a características de discriminación a utilizar para diferenciar entre zona buena o zona defectuosa se refiere. Esto se logra enfatizando las zonas que presentan defectos.
2. Implique un coste computacional menor. Esto se logra como consecuencia del punto anterior; ya que la sencillez en el proceso de discriminación trae como consecuencia el uso de un menor número de descriptores y algoritmos más simples.
3. Sea más fiable en su diagnóstico. Esto se logra eliminando efectos indeseables que puedan estar presentes en las imágenes originales, concretamente:

- * Presencia de ruido.
- * Iluminación no uniforme.

Como ya se ha comentado todo proceso de imágenes, y por tanto todas aquellas técnicas de preprocesamiento de imágenes, se puede modelar como una transformación entre dos espacios, espacio de entrada $I(y,x)$ y de salida $F(y',x')$, que es llevada a cabo por un sistema, $R(y,x,t)$, constituido por un conjunto de elementos computacionales. Particularmente, para los procesos que se describen en esta sección se tiene que sus $R(y,x,t)$ asociados poseen las siguientes características:

1. El espacio de salida sólo es función de los elementos del espacio de entrada. Esto es, no existe realimentación.
2. Todos los elementos computacionales realizan la misma función; por lo que son espacialmente invariantes.
3. Poseen también invarianza temporal, esto es:

$$R(y, x, t) = R_0$$

El espacio de salida está formado por una matriz, cuyas dimensiones son menores o iguales que las dimensiones de la matriz que forma el espacio de entrada, cuando son menores se dice que el proceso produce un efecto de borde. Cada elemento de la matriz direcciona a una variable, $F(y', x')$, que almacena el resultado, este resultado se obtiene aplicando los elementos computacionales en el espacio de entrada:

$$F(y', x') = R_0 [I(y, x)]$$

2.2.2.1. Ecuación del histograma.

Este método pertenece al conjunto de técnicas de realce de imágenes en el dominio espacial [Wood 81]. Básicamente consiste en realizar una transformación que se define como:

$$F(y, x) = T [I(y, x)] = \sum_{j=0}^{I(y, x)} h(j)$$

Es decir, el nivel de gris asociado a todo punto de la imagen original, $I(y, x)$, se transforma en un nivel de gris $F(y, x)$ en la imagen transformada en base al

histograma h de la imagen original I . El objetivo de esta transformación es obtener una imagen transformada que presente un histograma más ancho que el que presenta la imagen original. De esta manera se tiene una imagen realzada, de detalles más contrastados.

Un problema que presenta esta técnica de realce consiste en que los detalles de dimensiones pequeñas de la imagen original, que pueden ser relevantes en procesos posteriores, no quedan suficientemente destacados. Efectivamente, en el caso de un ecualizado del histograma de toda una imagen, los detalles pequeños tienen una influencia insignificante en el histograma total de la imagen original, ya que aportan pocos puntos de imagen al histograma.

Para solventar este inconveniente se ha utilizado una variante del método anterior. Esta variante consiste en aplicar la técnica descrita en áreas locales de la imagen original. Las áreas locales utilizadas son ventanas de tipo rectangular y de dimensiones dependientes del tipo de textura. Formalmente esta técnica local de realce se puede expresar de la siguiente forma: sea $W(y,x)$ una región rectangular de dimensiones $n*m$ centrada en el punto de imagen cuyas coordenadas son (y,x) . Entonces el nivel de gris asociado a ese mismo punto en la imagen transformada, $F(y,x)$, se obtiene al aplicar la transformación:

$$F(y, x) = T_w [I(y, x)] = \sum_{j=0}^{I(y, x)} h_w(j)$$

Siendo $I(y,x)$ el nivel de gris asociado al punto (y,x) en la imagen original. T_w representa la transformación local cuyo dominio es el área local $W(y,x)$ y h_w es el

histograma de dicha región. Esta transformación local se puede aplicar de dos formas distintas. La primera consiste en dividir la imagen original en ventanas disjuntas (sin solapamiento), la segunda, opuesta a la estrategia anterior en resolución, consiste en aplicar la transformación desplazando la ventana con máximo solapamiento. El primer esquema si bien desde el punto de vista de cómputo posee un coste considerablemente menor que la segunda, tiene el inconveniente de producir un efecto "mosaico" en la imagen transformada.

2.2.2.2. Proceso Facilitador.

Un "Proceso Facilitador" se define como un proceso que realiza una tarea que hace que procesos posteriores, en la secuencia de ejecución, cumplan mejor sus objetivos a como lo harían sin la "acción facilitadora". Esta acción consiste en preprocesar el espacio de entrada para que los procesos posteriores logren una respuesta óptima.

En nuestro caso, necesitamos enfatizar aquellas áreas de la imagen de entrada que presenten defectos. La técnica que se propone consiste en un mecanismo multiplicativo de dos procesos locales. El primer proceso local calcula la diferencia en valor absoluto existente entre el nivel de gris asociado a un punto central de una área local y el promedio de los niveles de gris asociados a los puntos que pertenecen a dicha área. El segundo proceso local calcula la varianza de los niveles de gris de dicha área local. La salida $F(u,v)$ del proceso facilitador se obtiene multiplicando las salidas obtenidas por los procesos locales anteriores.

El método es una transformación local entre imágenes basada en integrales

locales de superficie que se calculan en la imagen original $I(u,v)$ [Candela 93]. La formulación en continua es:

$$F(u, v) = |I(u, v) - X_w| \sigma_w^2$$

Siendo:

$$X_w = \frac{1}{|W|} \int_w I(u, v) dudv$$

$$\sigma_w^2 = \frac{1}{|W|} \int_w (I(u, v) - X_w)^2 dudv$$

Por tanto, para definir totalmente la transformación es necesario primero definir el tipo de área local Ω a utilizar. Una vez especificada, cada valor $F(u,v)$ se obtiene al aplicar las expresiones anteriores en cada región Ω definida en torno a cada punto (u,v) de la imagen original I .

Para el caso discreto, si tomamos regiones rectangulares $W(y,x)$, W centrada en el punto de coordenadas (y,x) de la imagen original I , se deben establecer las dimensiones de cada región. Si d_y representa la dimensión vertical expresada en número de puntos, y d_x la horizontal, entonces para cada área local $W(y,x)$ definida en la imagen original se deben calcular los valores de X_w y σ_w^2 a partir de los niveles de gris asociados a los puntos que pertenecen a $W(y,x)$. Siendo sus expresiones discretas:

$$X_w = \frac{1}{dydx} \sum_{i=y-dy/2}^{y+dy/2} \sum_{j=x-dx/2}^{x+dx/2} I(i, j)$$

$$\sigma_w^2 = \frac{1}{dydx} \sum_{i=y-dy/2}^{y+dy/2} \sum_{j=x-dx/2}^{x+dx/2} (I(i, j) - X_w)^2$$

Donde el producto $dy \cdot dx$ es el número de puntos de imagen del área $W(y,x)$. $I(i,j)$ representa los niveles de gris de dichos puntos. Si $I(y,x)$ es el nivel de gris del punto central de $W(y,x)$, entonces el valor que toma ese mismo punto en la imagen transformada es:

$$F(y, x) = |I(y, x) - X_w| \sigma_w^2$$

Se deben comentar los siguientes aspectos:

1. El dominio de la transformación son todos los puntos de la imagen original, (y,x) , que cumplen:

$$\frac{d_y}{2} \leq y \leq L_y - \frac{d_y}{2}$$

$$\frac{d_x}{2} \leq x \leq L_x - \frac{d_x}{2}$$

Siendo L_y y L_x las dimensiones verticales y horizontales de la imagen original.

2. La imagen resultado posee una dimensión horizontal y vertical $L_y - d_y + 1$ y $L_x - d_x + 1$ respectivamente.

Para describir el comportamiento de la transformación reducimos al caso de funciones de entrada unidimensionales. Esta simplificación nos facilita el conocimiento del comportamiento del método sin perder su validez para el caso bidimensional. Concretamente, el estudio que se describe a continuación consiste en evaluar la salida que se produce ante señales de entrada típicas e ideales, pulso y rampa. Seguidamente, y para aproximarse más a la realidad, se estudió el comportamiento con señales

unidimensionales con ruido.

En primer lugar, el comportamiento ante señales ideales, pulso unitario y rampa de pendiente unitaria, nos demuestra que la transformación se comporta como un detector de flancos. Como ilustración de esta afirmación se presentan las siguientes figuras donde primero se muestra el comportamiento ante un pulso de entrada, figura 2.4, y a continuación se ilustra el comportamiento ante una rampa de entrada, figura 2.5.




Figura 2.4. Respuesta ante un pulso de entrada




Figura 2.5. Respuesta ante una rampa de entrada

Un aspecto importante del método es la influencia de la dimensión del área local de proceso W en la respuesta obtenida. Para ello, partiendo de las expresiones en continuo de X y σ , se ha estudiado la respuesta obtenida variando la dimensión de W ante un pulso de entrada. Si se asume la siguiente notación: $S(x)$ es la señal de entrada, b su amplitud, $2a$ el ancho del pulso (figura 2.6) y $2h$ la longitud del intervalo de integración W :




Figura 2.6. Pulso genérico

Si partimos de la formulación del método en continua para el caso unidimensional:

$$F(u) = |S(u) - X_W| \sigma_W^2$$

$$X_W = \frac{1}{2h} \int_{x-h}^{x+h} S(u) du$$

$$\sigma_W^2 = \frac{1}{2h} \int_{x-h}^{x+h} (S(u) - X_W)^2 du$$

Como estamos en el caso unidimensional la región local de integración, $W(x)$, es un intervalo de tamaño $2h$ centrado en cada punto x del espacio de entrada. Las conclusiones que se obtienen de este estudio se reflejan en los siguientes cuatro casos

*** Caso 1: $h < a$** Esto significa que el tamaño de área de proceso es menor que la mitad del ancho del pulso de entrada.




Figura 2.7. Forma de la respuesta general en el Caso 1.

Caso 2: $h=a$ Esto significa que el tamaño del área de proceso es igual que el ancho de la señal de entrada.




Figura 2.8. Forma de la respuesta general en el Caso 2.

Caso 3: $h > a \wedge h < 2a$ Esto significa que el tamaño del área de proceso es mayor que el ancho del pulso, pero la mitad de dicha área no supera el ancho total del pulso.




Figura 2.9. Forma de la respuesta general en el Caso 3.

Caso 4: $h > 2a$. Tanto el tamaño del área de proceso como su mitad superan el ancho del pulso de entrada.




Figura 2.10. Forma de la respuesta general en el Caso 4.

Otro aspecto a estudiar consiste en conocer cómo se comporta el método ante señales ruidosas. Para abordarlo se han degradado las entradas ideales anteriores con una componente de ruido, simulada por una función generadora de números aleatorios que sigue una distribución $N(0,1)$ que se añade a cada punto de muestreo de la señal de entrada. En la siguiente figura se ilustra el comportamiento del método ante una rampa degradada con ruido.




Figura 2.11. Respuesta ante una rampa con ruido.

Para ayudar a conocer el comportamiento del método ante señales con ruido, se ha utilizado una función de error que se define en cada punto como la diferencia al cuadrado entre la salida ideal F_I señal sin ruido, y la salida ante la señal ruidosa F_R . Esto es:

$$E(x) = (F_I(x) - F_R(x))^2$$

Observando las distintas funciones $E(x)$ obtenidas en las pruebas realizadas se desprende que el método posee un buen comportamiento ante señales ruidosas, ya que por un lado se sigue comportando como un detector de flancos, y además, las respuestas ante señales ruidosas están muy próximas a las respuestas ideales. Para ilustrar esto último se presenta la siguiente figura que nos muestra la función error, $E(x)$, obtenida en función de la respuesta ante una rampa ideal y la respuesta ante esa rampa degradada.




Figura 2.12. Rampa degradada con ruido gaussiano.




Figura 2.13. Respuesta y E(x) para la rampa degradada anterior.

Desde el punto de vista de implementación, el método tiene las siguientes peculiaridades [Candela 93]:

1. Tiene un algoritmo rápido.
2. Se puede ejecutar por una red de elementos de cómputo paralelos.

Para explicar las dos propiedades anteriores debemos reformular la expresión de σ_w . Esta nueva expresión es:

$$\sigma_w^2 = \frac{\sum_{i=y-dy/2}^{y+dy/2} \sum_{j=x-dx/2}^{x+dx/2} I^2(i, j)}{N} - X_w^2$$

El método admite un algoritmo rápido que además posee la propiedad de que el número de operaciones a realizar es casi independiente del número de puntos que configuran la región local $W(y,x)$. Esta afirmación se basa en que los valores de X_w y σ_w asociados a un punto (y,x) , que posee puntos vecinos de coordenadas $(y,x-1)$ y $(y-$

l,x), se obtienen a partir de valores obtenidos previamente. Concretamente, si $X_{W(y,x)}$ representa el valor de X_w en el punto (y,x) y si se define el valor intermedio $C(y,x)$ como:

$$C(y, x) = \frac{1}{N} \sum_{i=y-dy/2}^{y+dy/2} I(i, x)$$

Entonces:

$$X_{W(y,x)} = X_{W(y,x-1)} - C(y, x-dx/2-1) + C(y, x+dx/2)$$

Se llega a un cálculo de X_w en donde el número de operaciones a realizar es independiente del número de puntos que forman el área local W . Análogamente ocurriría con el cálculo de σ_w si se aplican las expresiones:

$$E(y, x) = \frac{1}{N} \sum_{i=y-dy/2}^{y+dy/2} I(i, x)^2$$

$$\sigma_{W(y,x)}^2 = \sigma_{W(y,x-1)}^2 + \frac{1}{N} (E(y, x+dx/2) - E(y, x-dx/2-1))$$

La segunda propiedad consiste en que la transformación se puede llevar a cabo mediante una red de elementos de cómputo paralelos básicos, sumadores y multiplicadores de pares de valores, que tiene la topología que se expresa en la siguiente figura:

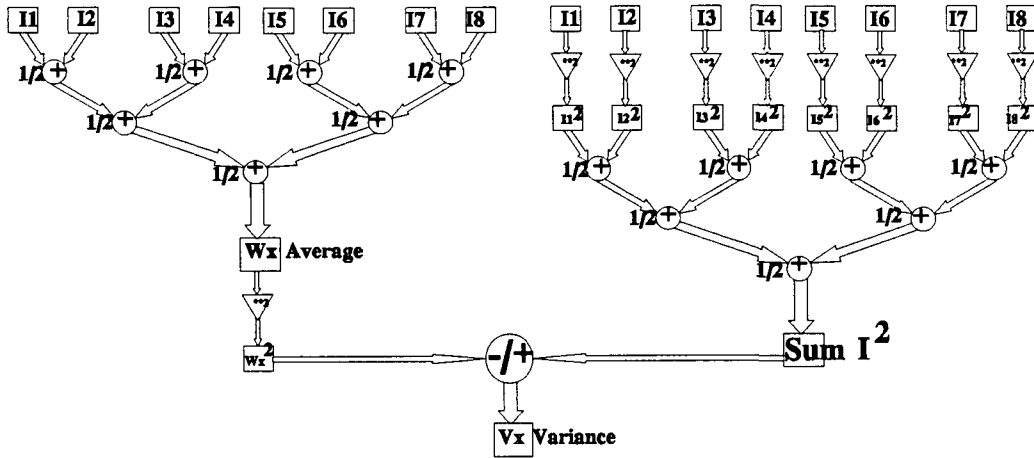


Figura 2.14. Red de cómputo paralelo del método

Aplicación del Proceso Facilitador a imágenes.

La formulación de la transformación propuesta se originó a partir de las experiencias realizadas con los ejemplos de imágenes de pieles con imperfecciones. Concretamente, en las pruebas realizadas se observó frecuentemente que en las zonas de las imágenes que presentaban defectos se producían cambios en la media (cuando el defecto se manifestaba como transiciones de áreas claras a oscuras o viceversa) o en la varianza (caso de imperfecciones estructurales). En base a este comportamiento se pensó en la posibilidad de plantear algún tipo de transformación cuya expresión fuese función de los parámetros anteriores y que tuviera como principal característica de comportamiento una alta sensibilidad a la presencia de defectos (efecto de contraste en

las áreas con imperfecciones), como resultado de estos planteamientos se formuló la técnica facilitadora descrita. Seguidamente para mostrar su comportamiento y su utilidad en el marco de la inspección visual automática se presentan dos ejemplos, correspondientes a una imagen de piel de vaca y otra de cerdo con defectos. A través de estos ejemplos se ilustra también la influencia del tamaño del área local en el resultado de la transformación. La imagen superior izquierda corresponde a la piel de cerdo y la imagen inferior izquierda corresponde a la piel de vaca. En la primera ilustración se presenta el resultado para una ventana cuadrada de dimensión 7, en ella se puede apreciar cómo los defectos no son contrastados. En la segunda ilustración se muestra el resultado para una ventana cuadrada de dimensión 15, apreciándose un mayor contraste de los defectos con respecto al caso anterior. Por último, se presenta el resultado para dimensión 31, poniéndose de manifiesto el carácter enfatizador de defectos de la transformación.




Ilustración 2.1. Resultado del preproceso para un área local cuadrada de dimensión 7.




Ilustración 2.2. Resultado del preproceso para un área local cuadrada de dimensión 15.




Ilustración 2.3. Resultado del preproceso para un área local cuadrada de dimensión 31.

2.2.3. Definición del área local de trabajo .

Debido a que el esquema de detección es de carácter local, es necesario por tanto establecer convenientemente las dimensiones del área local, ventana de trabajo en adelante, a utilizar en la caracterización. A la hora de establecer dichas dimensiones se deben tener en cuenta los siguientes factores:

- 1. Tipo de textura.** Si ésta se compone de patrones perfectamente identificables y organizados espacialmente de manera regular, entonces la elección de las dimensiones de la ventana de trabajo se puede realizar manualmente. En cambio, si no es éste el tipo de textura problema (por ejemplo texturas modelizables mediante distribuciones aleatorias de los niveles de gris) se debe acudir a técnicas más o menos sofisticadas basadas en análisis de comportamiento de los parámetros utilizados en la caracterización de la textura, basados en análisis estadísticos o de estabilidad.
- 2. Descriptor utilizado en la caracterización.** Esto se debe al hecho de que la naturaleza del descriptor hace, en ocasiones, que se deba acotar bien la dimensión mínima asumible, o bien la dimensión máxima. Concretamente, para dimensiones muy reducidas no son aplicables parámetros de naturaleza estadística, en el polo opuesto, dimensiones muy grandes pueden motivar que se degrade el comportamiento del descriptor.
- 3. Dimensiones de los defectos a detectar.** Si éstas son reducidas, entonces si se utilizan ventanas de trabajo muy grandes se corre el riesgo de insensibilizar el proceso de detección.

Para establecer unas dimensiones apropiadas se ha aplicado un método que se fundamenta en el paradigma planteado, consistente en un análisis de estabilidad de parámetros estadísticos. Seguidamente se describe dicho método, en primer lugar se expondrán sus fundamentos en relación con el paradigma planteado, y a continuación, se procederá a su descripción formal ilustrándolo con resultados.

Fundamentos teóricos.

La técnica empleada para la determinación del tamaño de la ventana de trabajo, que se denotará por W y tendrá una dimensión d , se puede formular de la siguiente manera. Sea $I(y,x)$ una subimagen, que presenta una determinada textura, que posee las siguientes propiedades:

1. No posee defecto alguno.
2. $R(y,x)$ es una convolución generalizada que mide cierta propiedad relevante de la textura.
3. Para $I(y,x)$ y $R(y,x)$ se tiene que la unidad mínima de representación es W_R cuya dimensión es d_R (supuesta con forma cuadrada).

Entonces en función de las dimensiones d y d_R se tendrá que la imagen de diferencias generada al aplicar $R(y,x)$ sobre $I(y,x)$ se comportará de la siguiente manera:

Caso 1º: si $d < d_R$, entonces la imagen de diferencias no es uniforme, debido a que se ha utilizado una ventana de trabajo menor que la mínima requerida para que la propiedad relevante evaluada por $R(y,x)$ se ponga de manifiesto.

Caso 2º : si $d \geq d_R$, entonces la imagen de diferencias es uniforme (espacio de diferencias estable). Este comportamiento se debe a que $I(y,x)$ presenta una única textura y la caracterización se realiza sobre ventanas de trabajo de dimensión igual o mayor que la mínima requerida para que la propiedad relevante evaluada por $R(y,x)$ se ponga de manifiesto.

Al llevar a la práctica este comportamiento en el marco de un sistema de detección automática de defectos se tendrá que d podrá admitir un rango $[d_{\min}, d_{\max}]$ de dimensiones válidas, ya que:

- El mínimo d_{\min} será aquel valor a partir del cual la imagen de diferencias se hace casi constante (obviamente totalmente constante es una idealización).
- El máximo d_{\max} vendrá fijado por aspectos ajenos a la textura en sí y son referentes a la bondad del proceso de detección. Concretamente, a partir de una dimensión dada de la ventana de trabajo el diagnóstico producido se degrada debido a: existirán defectos no detectables (por ejemplo los de dimensiones reducidas), o bien, por degradación del comportamiento del parámetro de caracterización empleado.

Descripción del método empleado:

Éste se puede describir de la siguiente manera:

1. Seleccionar una subimagen que no posea defecto alguno.
2. Seleccionar una propiedad relevante evaluada por una regla genérica $R(y,x)$.
3. "Para" $d = d_0$ hasta d_1 "hacer"

Calcular imagen de autocorrelación asociada a $R(y,x)$.

Calcular imagen de diferencias $D(y,x)$.

Evaluar el grado de uniformidad de la imagen de $D(y,x)$.

"Fin para"

4. Seleccionar aquellos valores de d tal que a partir de los mismos se alcanza un cierto grado de uniformidad establecido a priori.
5. Para los valores seleccionados en el punto 4º calcular su promedio.

La cuestión que surge es ¿cómo evaluar el grado de uniformidad de la imagen de diferencias $D(y,x)$? En la implementación que se ha realizado, esta evaluación se realiza mediante el cálculo de la varianza que se puede interpretar como el error existente entre $D(y,x)$ y la imagen de diferencias ideal uniforme, $U(y,x)$, que adopta el valor medio de $D(y,x)$. De forma algorítmica se expresaría:

1. Calcular valor promedio de $D(y,x)$.

$$\mu = \sum_y \sum_x \frac{D(y, x)}{np}$$

2. $U(y,x) = \mu$

3. Calcular error medio:

$$Err = \sqrt{\frac{\sum_y \sum_x (D(y, x) - U(y, x))^2}{np}}$$

Para el caso de los materiales analizados se ha concluido que para las pieles de cerdo la dimensión de la ventana de trabajo está entorno a 31 y para las de vaca 15.

Seguidamente se ilustra esta técnica de la siguiente manera: en primer lugar, se presenta una imagen en la que se ha seleccionado una zona de estudio (sin defectos). A continuación, se muestran las gráficas de comportamiento para los parámetros media, varianza, distancia euclídea y distancia de Bhattacharyya. Por último se presentan resultados de diagnóstico utilizando distintas áreas (15,31,61), en ellos se pone de manifiesto lo expresado anteriormente: para ventanas pequeñas (15) se producen espúreos, para ventanas cuyo tamaño está dentro de la zona estable (31) los diagnósticos son aceptables, esto es, no abundan espúreos y el tamaño del defecto no es crítico de cara a la detección. Finalmente para ventanas de tamaño muy grande (61) el diagnóstico se degrada.

Cabe añadir que esta estrategia también sirve para darnos una idea sobre la utilidad de los descriptores, obsérvese la diferencia de comportamiento de la distancia de Bhattacharyya.




Ilustración 2.4. Zona seleccionada para el estudio de la dimensión de la ventana de trabajo.

GRÁFICOS DE COMPORTAMIENTO.

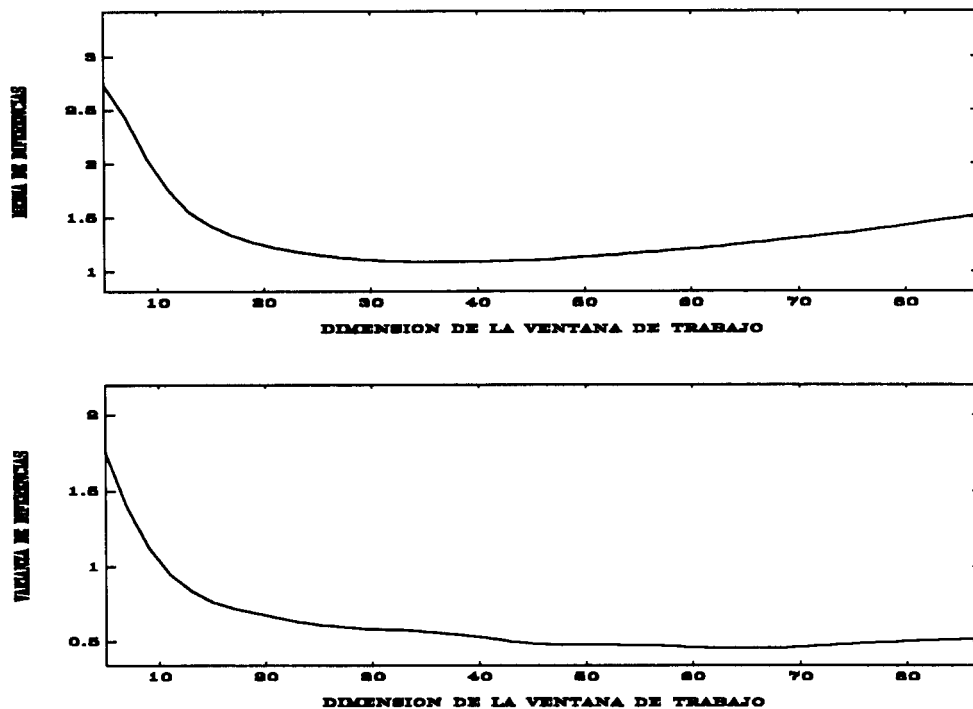


Figura 2.15. Media: comportamiento ante distintas dimensiones de ventana.

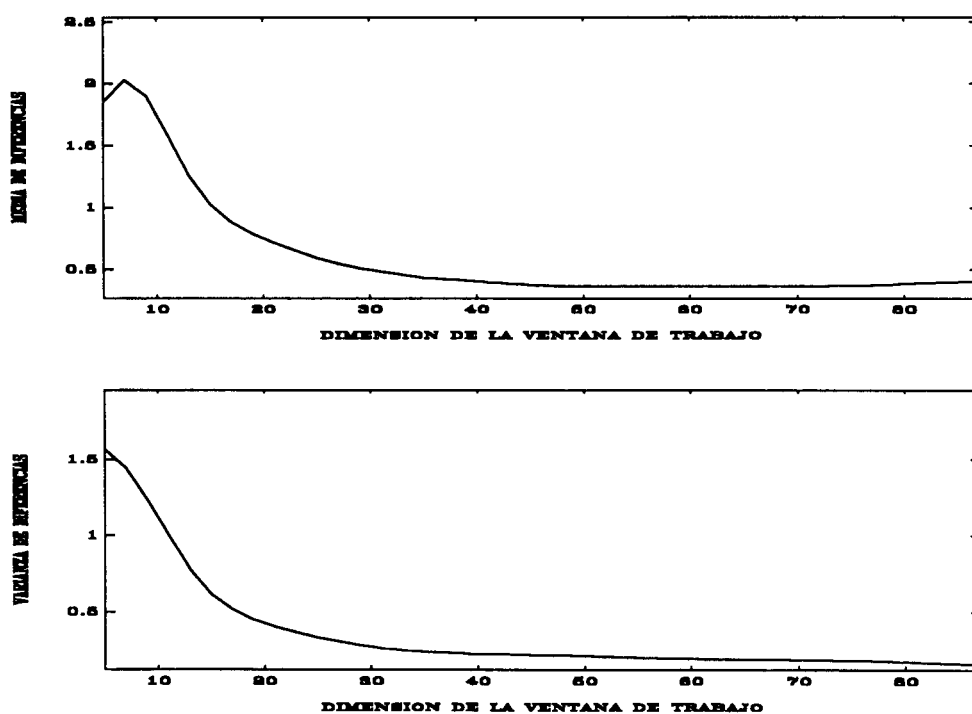


Figura 2.16. Varianza: comportamiento ante la dimensión de la ventana.




Figura 2.17. Distancia euclídea frente a la dimensión de la ventana.

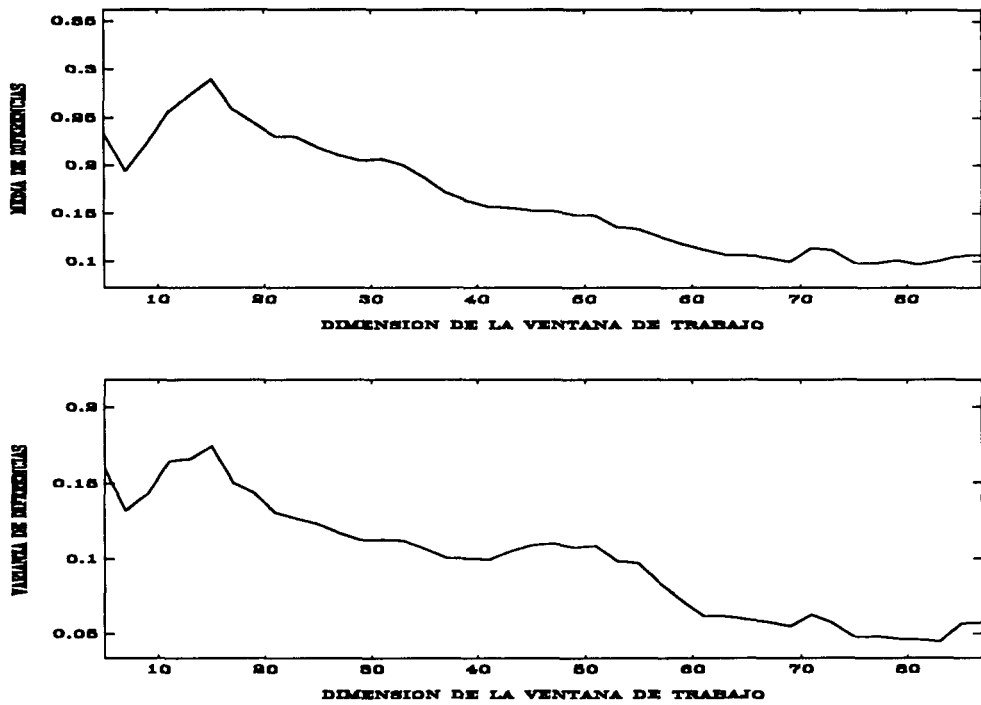


Figura 2.18. Distancia de Bhattacharyya frente a la dimensión de la ventana.




Ilustración 2.5. Distancia euclídea. Fases del proceso de diagnóstico para una ventana de 15. Imagen original en esquina superior izquierda, superior derecha imagen de característica, imagen de diferencia en inferior izquierda y diagnóstico en derecha.




Ilustración 2.6. Distancia euclídea. Proceso de diagnóstico para una ventana de 31. Imagen original superior izquierda, imagen de características superior derecha, imagen de diferencia inferior izquierda y diagnóstico en la inferior derecha.




Ilustración 2.7. Distancia euclídea. Proceso de diagnóstico para una ventana de 61. Imagen original esquina superior izquierda, a la derecha imagen de características, imagen de diferencia en la inferior izquierda y diagnóstico en la inferior derecha.

2.2.4. Cómputo de descriptores.

En este punto de la estrategia se aplican distintas reglas genéricas sobre cada ventana de la imagen de entrada preprocesada, basadas en núcleos algebraicos o algorítmicos, con la finalidad de obtener un vector de características que la represente en el espacio de los descriptores. Un aspecto importante relacionado con este punto es el grado de resolución de las convoluciones; entendiéndose como resolución de la convolución el desplazamiento que se aplica al núcleo. Si suponemos una ventana de trabajo cuadrada de dimensión d , entonces la resolución máxima se obtiene cuando el desplazamiento es 1 (máximo solape) y la mínima cuando este es $d/2 + 1$ (ventanas disjuntas). El establecimiento de este parámetro depende fundamentalmente de la sensibilidad del núcleo utilizado ante los defectos y el tamaño de los bordes que separan las zonas buenas de las defectuosas. Entre los descriptores a utilizar caben mencionar [Reed 93]:

1. Estadísticos de primer orden. Están inspirados en Estadística o en la Teoría de la Información, su denominación de primer orden viene del hecho de que pueden calcularse a partir del histograma de la imagen. Ejemplo de este tipo de descriptores son: Media, Varianza, Kurtosis, Apuntamiento, Mediana, Energía, Sinergia, Entropía, etc.

2. Métricas entre histogramas. Esta técnica toma como descriptor de textura el histograma. La caracterización se establece en base a métricas. Ejemplos de métricas utilizadas son las que se establecen en base a: Distancia Euclídea, Distancia de Mahalanobis y Distancia de Bhattacharyya. Una variante de esta metodología está inspirada en la Teoría Estadística es la utilización de Tests de

Bondad de Ajuste como función de similitud entre las distribuciones de los niveles de gris que presentan las texturas.

3. Estadísticos de segundo orden. Inspirados, al igual que los de primer orden, en la Estadística y la Teoría de la Información. El calificativo de segundo orden proviene del hecho de que se obtiene a partir de distribuciones probabilísticas de segundo orden (matrices de coocurrencia y distribuciones de diferencias de niveles de gris). Son ejemplos de este tipo de descriptores: Autocorrelación, Covarianza, Inercia, Módulo, Energía, Entropía, Diferencia Inversa, etc.

4. Respuesta ante núcleos lineales. Se utiliza como característica la respuesta que se produce al convolucionar la textura con filtros que generalmente son sensibles a características topológicas o a cambios en las frecuencias de los niveles de gris.

5. Modelos de Faceta. Básicamente esta estrategia consiste en caracterizar texturas mediante propiedades topológicas. Estas propiedades (cimas, valles, cráteres, etc) se pueden caracterizar, en superficies teóricas ideales, en base a derivadas direccionales de distintos órdenes. Debido a que en la realidad las imágenes no se asemejan a superficies ideales estas se ajustan a superficies teóricas de referencia, pasando a continuación al estudio topológico.

6. Dominio de la frecuencia. Se aplica con considerable éxito en situaciones donde la textura problema es periódica. A partir de la Transformada de Fourier se obtienen un conjunto de descriptores que tienen la propiedad de ser altamente sensibles a variaciones en la periodicidad de la imagen problema.

Esquema algorítmico de cálculo rápido de descriptores.

El tiempo de respuesta (definiéndose como el tiempo requerido para producir un diagnóstico) es un factor crítico en los sistemas de inspección automática, por tanto es importante utilizar algoritmos rápidos de cálculo susceptibles de ser utilizados por ellos. En el marco de la metodología propuesta de detección la fase más crítica, en lo que al tiempo de respuesta se refiere, es esta de cálculo de descriptores, ésto se debe a:

1. Su carácter local, que en el caso extremo implica realizar una caracterización por cada punto de la imagen a inspeccionar (máxima resolución en la caracterización).
2. El tipo de descriptores, que en ocasiones implican un número considerable de operaciones, siendo un ejemplo los estadísticos de segundo orden.

Se ha desarrollado un esquema algorítmico de cálculo rápido de descriptores que se puede aplicar para obtener, entre otros, los siguientes parámetros:

1. Momentos de cualquier orden de distribuciones estadísticas de primer orden. Por tanto, debido a que se pueden expresar como funciones de estos, se podrá utilizar para el cálculo de la: Media, Varianza, Curtosis, Apuntamiento.
2. Estadísticos de segundo orden que adoptan la forma:

$$\sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P(i, j) f(i, j)$$

Siendo $P(i,j)$ la matriz de co-ocurrencia (representación de la distribución de segundo orden), i y j están asociados a niveles de gris y $f(i,j)$ una función genérica definida entre pares de niveles de gris que cumplen con la relación

espacial $S_{\theta,d}$ utilizada para definir la distribución de segundo orden. Ejemplo de parámetros que siguen esta expresión son:

$$\text{Contraste: } \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P(i, j) |i-j|^2$$

$$\text{Momento de la diferencia inversa: } \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} \frac{P(i, j)}{1+|i-j|^2}$$

$$\text{Autocorrelación: } \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P(i, j) ij$$

Este esquema algorítmico parte de una reformulación de los descriptores a calcular basada en una secuencia de transformaciones entre imágenes, esta secuencia adopta la forma genérica:

$$I(y, x) \rightarrow^{T_1} H(y, x) \rightarrow^{T_2} C(y, x)$$

Siendo $I(y,x)$ la imagen original, $H(y,x)$ una imagen intermedia y $C(y,x)$ la imagen de características. En cuanto a las transformaciones:

$T_1: I(y,x) \rightarrow H(y,x)$ es una transformación punto a punto, que para el caso de los estadísticos de segundo orden se realiza tomando las parejas de puntos de la imagen original que cumplen la relación espacial $S_{\theta,d}$ utilizada para definir la distribución de segundo orden.

$T_2: H(y,x) \rightarrow C(y,x)$ es una convolución cuyo núcleo asociado puede poseer coeficientes nulos y los no nulos son todos constantes. Para el caso de estadísticos de primer orden éste tendrá unas dimensiones iguales a las del área local a caracterizar y sus coeficientes serán todos iguales a 1. Para los

estadísticos de segundo orden, la máscara tendrá coeficientes nulos y los no nulos serán iguales a 1, en cuanto a sus dimensiones, éstas serán iguales a las del área local utilizada. Sobre estas convoluciones hay que decir que estas máscaras, desde el punto de vista de implementación, poseen una propiedad importante consistente en que se pueden llevar a cabo aplicando algoritmos que utilizan cálculos ya realizados previamente para producir nuevos resultados, de forma que el número de operaciones a realizar es casi independiente del tamaño de la máscara.

Como ilustración de lo expuesto se presenta a continuación algunos casos de cálculo de parámetros:

Ejemplo 1: Cálculo de estadísticos de primer orden.

Se expondrá cómo se aplicaría el esquema para obtener los momentos de orden n respecto a 0 y a la media. Esto valdría para generar cualquier parámetro que fuese función de los momentos mencionados, como por ejemplo: media, varianza, curtosis y apuntamiento.

1. Momento n -ésimo respecto al 0:
$$Q_{0n} = \frac{1}{N} \sum_{i=0}^{r-1} h(i) i^n$$

* La transformación $T_1: I(y,x) \rightarrow H(y,x)$ adquiere la forma:

* La transformación $T_2: H(y,x) \rightarrow C(y,x)$ será la convolución definida por

$$H(y, x) = (I(y, x))^q$$

la máscara $k = 1$ de dimensiones iguales a las de la ventana de trabajo, es decir:

$$C(y, x) = H(y, x) * K(u, v)$$

2. Cálculo del momento de orden n con respecto a la media.

$$Q_{xq} = \frac{1}{N} \sum_{i=0}^{r-1} [h(i) (i-x)^q]$$

* La transformación $T_1: I(y, x) \rightarrow H(y, x)$ será de la forma:

$$H(y, x) = (I(y, x) - X)^q$$

Siendo X la media del área local a caracterizar cuyo punto central es (y, x) . Hay que hacer notar que la media es el momento de orden 1 con respecto al origen y por lo tanto se calcula de acuerdo con lo descrito anteriormente.

* La transformación $T_2: H(y, x) \rightarrow C(y, x)$ será de la forma:

$$C(y, x) = H(y, x) * K(u, v)$$

Siendo k un núcleo idéntico al descrito en el ejemplo anterior.

Ejemplo 2: Cálculo de estadísticos de segundo orden del tipo:

$$\sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P(i, j) f(i, j) \text{ , siendo } S_{\theta,d} \text{ la relación espacial establecida para}$$

definir P(i,j).

* La transformación $T_1: I(y,x) \rightarrow H(y,x)$ será de la forma:

$$H(y, x) = f [I(y, x) , I(y', x')] , (y, x) R(S_{\theta,d}) (y', x')$$

Que en el caso de:

- Contraste: $f [I(y, x) , I(y', x')] = | I(y, x) - I$

- Homogeneidad: $f [I(y, x) , I(y', x')] = \frac{1}{1 + (| I(y, x$

- Autocorrelación: $f [I(y, x) , I(y', x')] = I(y, x) I$

* La transformación $T_2: H(y,x) \rightarrow C(y,x)$ será de la forma:

$$C(y, x) = H(y, x) * K(u, v)$$

Siendo $K(u,v)=1$ y de dimensiones dependientes de las dimensiones d_x y d_y del área local a caracterizar y de la relación espacial $S_{\theta,d}$. Por ejemplo:

- Si $d_y=15$, $d_x=15$ y $S_{\theta,d}$ es de la forma $(90^\circ, 1)$, entonces $d_{ky}=14$ y $d_{kx}=15$.

- Si $S_{\theta,d}$ es de la forma $(180^\circ, 1)$, entonces $d_{ky}=15$ y $d_{kx}=14$.

2.2.5. Cálculo del grado de homogeneidad local.

Como ya se ha mencionado el concepto de variación local de la textura se asocia a la ruptura local de la homogeneidad de una cierta propiedad local de la imagen. En este punto se plantea el problema de cómo medir el grado de homogeneidad entre regiones locales de la imagen.

Intuitivamente, el concepto de homogeneidad se suele asociar al concepto de similaridad, de forma que la resolución del problema planteado se establece formalmente mediante el uso de espacios métricos. Siguiendo esta línea, la forma que se propone para resolver el problema es mediante funcionales, basados en las características utilizadas en el proceso de representación, que evalúan el grado de alejamiento, que en nuestro caso se asocia a disimilaridad, entre regiones. Antes de pasar a describir las distintas formulaciones utilizadas para medir el grado de homogeneidad, conviene recordar las propiedades que toda función debe cumplir para que se le denomine función de distancia.

Sea E un conjunto no vacío, una métrica o distancia definida en E es una aplicación de $E \times E \rightarrow \mathbb{R}$, tal que a cada par de elementos (x,y) de E le asocia un número real, que cumple las siguientes propiedades:

1. $d(x,y) \geq 0 \quad \forall x,y \in E$
2. $d(x,y) = 0 \Leftrightarrow x=y$
3. $d(x,y) = d(y,x) \quad \forall x,y \in E$
4. $d(x,z) \leq d(x,y) + d(y,z) \quad \forall x,y,z \in E$

Se denomina espacio métrico al par $\{E,d\}$ formado por un conjunto E , que en

el caso particular que nos ocupa está constituido por los puntos del espacio n -dimensional que se constituye a partir de las características utilizadas en la representación, y la métrica definida en el mismo.

Distancia Euclídea.

Se trata de la función de distancia más utilizada, definiéndose a partir de las nociones de distancia entre dos puntos en un espacio y de la norma L2 de un vector.

$$d_e(x, y) = \sqrt{\sum_{i=0}^n (x_i - y_i)^2}$$

Esta métrica presenta la propiedad de ser invariante respecto a rotaciones y traslaciones.

Distancia Euclídea normalizada.

Se define como la distancia euclídea de un espacio normalizado. Esta normalización consiste en una transformación entre dos espacios métricos $T: E1 \rightarrow E2$ que no necesariamente tiene que conservar las distancias. Una de las razones para llevar a cabo esta normalización es salvar el inconveniente que se presenta al aplicar la distancia euclídea cuando los rangos de valores que pueden tomar las características empleadas difieren considerablemente. La normalización que se ha utilizado es de naturaleza estadística, consistente en transformar la característica en base a su media, μ_i , y varianza σ_i :

$$T(x_i) = X_i = \frac{(x_i - \mu)}{\sigma}$$

$$d_e(X, Y) = \sqrt{\sum_{i=0}^n (X_i - Y_i)^2}$$

De esta manera se pondera la contribución de cada característica en base a su media y varianza.

Distancia de Mahalanobis.

Se trata de una generalización de la distancia euclídea, ya que se define de la siguiente forma:

$$\|x\|^b = \sqrt{x^T B x}$$

$$d_m(x, y) = \sqrt{(x-y)^T B^{-1} (x-y)}$$

Donde B es la matriz de covarianzas de las características utilizadas, es decir:

$$B = \sigma_{ij} = \frac{\sum_{k=0}^m [(x_{ik} - \mu_i)(x_{jk} - \mu_j)]}{m}$$

Esta función de distancia tiene la propiedad de ser invariante a cualquier transformación lineal (traslaciones, rotaciones y cambios de escala). Hay que decir que a esta distancia se le denomina distancia estadística, pues se define en base a propiedades estadísticas, y posee la ventaja de tener en cuenta el grado de

independencia (correlación) entre las componentes de los vectores.

Distancias entre distribuciones probabilísticas.

Cuando la característica utilizada en la representación de una imagen es una distribución probabilística, para medir el grado de similaridad entre dos imágenes se aplican funcionales que miden el grado de proximidad entre funciones. Cuando la proximidad se establece en base a funcionales de distancia, formalmente se estará utilizando un espacio métrico {E,d}, siendo E un espacio donde cada punto está asociado a un función y d la distancia métrica utilizada. Concretamente las distribuciones probabilísticas que se han utilizado para la caracterización de texturas son histogramas (distribuciones probabilísticas de primer orden) y matrices de co-ocurrencia (distribuciones probabilísticas de segundo orden).

Las funciones de distancia utilizadas son las que a continuación se formulan:

* Euclídea:
$$d_e(h, H) = \sqrt{\sum_{i=0}^{r-1} (h(i) - H(i))^2}$$

* Battacharyya:
$$d_B(h, H) = \sqrt{\sum_{i=0}^{r-1} |h(i)^{1/2} - H(i)^{1/2}|}$$

* Mahalanobis:
$$d_M(h, H) = \sum_{i=0}^{r-1} \frac{|h(i) - H(i)|}{\sqrt{\frac{h(i)(1-h(i))}{N} + \frac{H(i)(1-H(i))}{N}}}$$

Para el problema planteado (caracterización de texturas), para interpretar este tipo de métricas se ha de contemplar a la distribución probabilística como una función definida en un dominio finito y acotada. Si además están asociadas a imágenes, entonces serán funciones discretas. Los histogramas en cambio constituyen la representación de una función discreta definida en el dominio $[0, r-1]$, siendo r el número de niveles de gris definidos en la imagen. Por otro lado, cuando se utilizan las matrices de co-ocurrencia, entonces se tratará de funciones discretas bidimensionales definidas en el dominio $[0, r-1] \times [0, r-1]$.

Si se considera el espacio métrico $\{E, d\}$, entonces el esferoide abierto de centro $x \in E$ y radio $r \in \mathbb{R}$, es el conjunto:

$$B(x, r) = \{y / y \in E, d(x, y) < r\}$$

El esferoide cerrado de centro $x \in E$ y radio $r \in \mathbb{R}$, es el conjunto:

$$B(x, r) = \{y / y \in E, d(x, y) \leq r\}$$

La esfera de centro x y radio r , es el conjunto:

$$S(x, r) = \{y / y \in E, d(x, y) = r\}$$

Para el caso particular de un conjunto E constituido por funciones continuas definidas en el intervalo $[A, B]$ y una función de distancia del tipo:

$$d_{ABS}(h(x), H(x)) = |h(x) - H(x)|$$

Entonces el esferoide $B(h(x), r)$ será el conjunto de todas las funciones $H(x)$ tales que $h(x) - r < H(x) < h(x) + r$. La siguiente figura ilustra dicho conjunto:




Figura 2.19. Esferoide según distancia $d_{ABS}(h(x), H(x))$

En cambio si la función d adopta la forma:

$$d_r(h(x), H(x)) = \int_A^B |h(x) - H(x)| dx$$

Entonces el esferoide abierto $B(h(x), r)$ es el conjunto de todas las funciones $H(x)$ continuas en $[a, b]$, tales que el área determinada por $|h(x) - H(x)|$ en $[a, b]$ es menor que r .

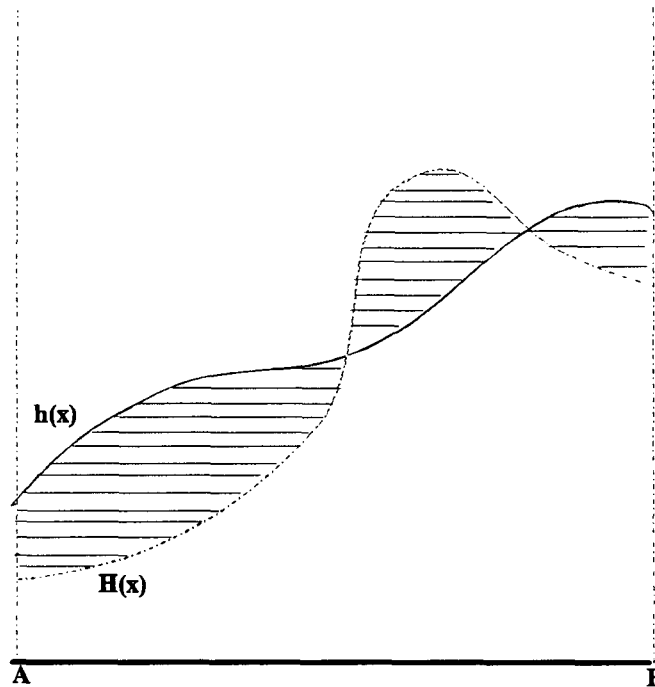


Figura 2.20. Esferoide según distancia $d_I(h(x), H(x))$

La proximidad de características individuales como medida de similitud.

Hasta ahora se han descrito funciones de distancia que hacen uso de todas las características utilizadas en el proceso de representación de la textura problema. Pero la siguiente cuestión ¿por qué utilizar combinaciones de parámetros de caracterización en expresiones algebraicas si cada uno representa una propiedad relevante y distinta?, está relacionada con esta otra más formal ¿si los parámetros de caracterización son independientes, por qué no medir la similitud a través de diferencias de características individuales?. Asumiendo la hipótesis de que las características empleadas en la representación son independientes y cada una de ellas miden propiedades relevantes y diferentes, entonces la similaridad se puede medir mediante expresiones de diferencias entre características individuales. Concretamente se propone las siguientes expresiones

para descriptores que adoptan en $\mathbb{R}^+ - \{0\}$:

$$d(A, B) = \frac{|A - B|}{\min(A, B)}$$

$$d(A, B) = \frac{|A - B|}{A + B}$$

Fácilmente se puede demostrar que ambas expresiones no establecen una métrica en un espacio constituido por la recta real $\mathbb{R}^+ - \{0\}$. Estas diferencias son medidas de proximidad existente entre dos puntos, con la propiedad de que tienen en cuenta los valores de los elementos a comparar; es decir, realizan una normalización con respecto al valor mínimo. Este detalle es importante si se recuerda el hecho de que las imperfecciones a detectar poseen una intensidad visual variable (tanto para defectos de distinto tipo como para de un mismo tipo).

A partir de las diferencias anteriores se puede definir una función de diferencias múltiple que hace uso un conjunto de descriptores:

$$d(x, y) = \sum_{i=0}^n K_i \frac{|x_i - y_i|}{\min(x_i, y_i)}$$

Seguidamente se ilustra el comportamiento de la diferencia relativa:

$$d(A, B) = \frac{|A - B|}{\min(A, B)}$$

En las imágenes que siguen se muestran el efecto de esta función que se resume como una normalización las diferencias del descriptor, permitiendo así, lograr una mayor independencia de la diferencias del descriptor con respecto a la intensidad visual

del defecto; detectando así defectos de poca intensidad visual y reduciendo diagnósticos espúreos. La primera ilustración se corresponde con una piel de vaca y la segunda es de cerdo, en ambas se muestra en primer término la imagen original, a continuación la imagen de media, seguidamente el diagnóstico alcanzado utilizando la diferencia $|A-B|$ y por último el diagnóstico alcanzado utilizando la diferencia relativa anterior. En todos los diagnósticos se ha utilizado como umbral el resultante de calcular $U = \mu + k \sigma$, siendo $k = 1,5$.




Ilustración 2.8. Comportamiento de la diferencia relativa. Imagen original en la parte superior izquierda, imagen de medias a la derecha, la inferior izquierda el diagnóstico utilizando la diferencia absoluta y la derecha utilizando la diferencia relativa.




Ilustración 2.9. Comportamiento de la diferencia relativa. Imagen original en la parte superior izquierda, imagen de medias a la derecha, la inferior izquierda el diagnóstico utilizando la diferencia absoluta y la derecha utilizando la diferencia relativa.

2.2.6. Reglas de decisión.

Una regla de decisión se puede contemplar como un algoritmo que implementa algún criterio para decidir sobre la calidad del material inspeccionado. Siguiendo el modelo planteado, que asocia al concepto defecto la ocurrencia de una ruptura de la homogeneidad de la textura analizada, las reglas de decisión se aplican sobre las imágenes de diferencias (en el caso de que el funcional empleado no establezca una métrica en el espacio de características) o de distancias (si sí la establece). Dependiendo del tipo y número de funcionales utilizados para medir el grado de similaridad se generarán un número dado de imágenes de diferencia. Por tanto, siguiendo la definición del defecto del modelo y asumiendo que el grado de similaridad se mide mediante funcionales de diferencias (o distancias) se tendrá que las reglas de decisión aplicables en este modelo adoptan una forma que en general será del tipo:

"Si" $D_{i,j} \geq U_{i,j}$ "entonces"

El área representada por (i,j) es defectuosa

"fin si"

Siendo $D_{i,j}$ el valor asociado al punto de coordenada (i,j) en una imagen de diferencias. $U_{i,j}$ será un umbral que podrá ser constante o bien variable, dependiendo de la zona inspeccionada (umbrales locales). Siguiendo lo descrito anteriormente se han probado distintos tipos de funcionales de distancia y de diferencia:

- Distancia Euclídea.
- Distancia Euclídea en un espacio de características normalizadas.
- Distancia de Mahalanobis.

- Diferencias absolutas.
- Diferencias relativas.

De las pruebas realizadas, considerando los factores de calidad del diagnóstico y coste de cómputo, se ha desarrollado un esquema de decisión como el ilustrado en la figura 2.3, donde las comparaciones locales se establecen en base a diferencias locales y donde cada imagen de diagnóstico primario se obtiene de la siguiente manera: sea $C_{i,j}$ el valor que adopta un determinado descriptor en el área local representada por su punto central (i,j) . Sea P el conjunto formado por todas las áreas locales que están situadas a una distancia constante k de (i,j) , esto es:

$$P = \{(i', j') / d_e[(i, j), (i', j')] = k\}$$

Si se define Q como el conjunto formado por cada uno de los valores que adopta el descriptor C en cada una de las áreas pertenecientes a P , entonces:

1. Para (i,j) y cada elemento de P , (i',j') , calcular el funcional:

$$d_{i,j} = \max \left(\frac{|C_{i,j} - C_{i',j'}|}{\min(C_{i,j}, C_{i',j'})} \right)$$

2. Aplicar la regla de decisión:

"Si" $d_{i,j} \geq U$ "entonces"

Área centrada en (i,j) es defectuosa según C

"fin si"

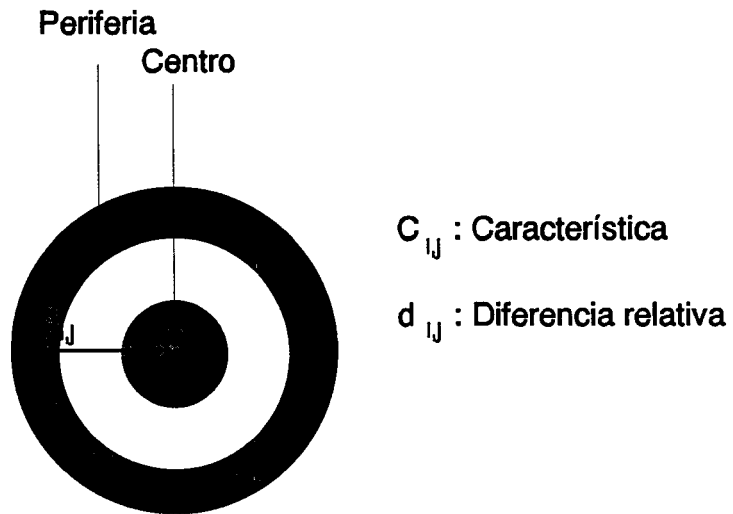


Figura 2.21. Distancia local.

Por tanto se deben establecer, en base a la textura a analizar y a los defectos a detectar, los siguientes valores:

- La constante k, en función de la que se define la periferia de una región.
- El valor de umbral U.

Cuando se aplican varias características se ha observado que pueden existir regiones que sin haber sido diagnosticadas como defectuosas, sus diferencias han estado muy próximas a los umbrales establecidos, teniendo por tanto una alta probabilidad de ser catalogados como tales. Para contemplar estos casos se propone el uso de funciones del tipo:

$$F.M.D. = \sum_{l=1}^{l=L} K * D_{ij}^l$$

Siendo L el número de características empleadas y d_{ij}^l la diferencia asociada al punto de coordenadas (i,j) en la imagen de diferencias generada con el l -ésimo descriptor.

A continuación se ilustra el esquema de decisión descrito mediante tres ejemplos. En el primero de ellos, ilustración 2.10, pone de manifiesto las ventajas de diagnosticar utilizando las imágenes de diferencias y no la de características: mayor diferenciación de las zonas defectuosas y una mayor inmunidad a iluminaciones no uniformes. En las dos restantes, ilustraciones 2.11 y 2.12, se ilustra el proceso de diagnóstico mostrando los diagnósticos primarios asociados a los descriptores media y distancia euclídea (imágenes superior derecha e inferior izquierda respectivamente) y el diagnóstico final mediante un OR lógico entre los diagnósticos primarios (imagen inferior derecha).




Ilustración 2.10. Imagen original en parte superior izquierda, imagen de medias en superior derecha, en inferior izquierda imagen de diferencias relativas y por último diagnóstico realizado sobre las diferencias relativas.




Ilustración 2.11. Superior izquierda imagen original, diagnóstico según media a su derecha, diagnóstico según distancia euclídea en inferior izquierda y a su derecha diagnóstico final.




Ilustración 2.12. Superior izquierda imagen original, diagnóstico según media a su derecha, diagnóstico según distancia euclídea en inferior izquierda y a su derecha diagnóstico final.

CAPÍTULO 3.

Métodos para la creación de Imágenes de Descriptores.

3.1. TÉCNICAS ESTADÍSTICAS DE PARA LA PRODUCCIÓN DE DESCRIPTORES.

Esta metodología se fundamenta en el uso de distribuciones de niveles de gris.

Básicamente se agrupan en:

Técnicas basadas en distribuciones o parámetros de primer orden. Se distingue entre aquellas que realizan la descripción en base a métricas definidas entre histogramas y las que lo hacen a partir de parámetros obtenidos del histograma. Estas últimas se puede definir genéricamente como estrategias que caracterizan texturas en base a descriptores estadísticos; que son funciones de momentos de distintos órdenes con respecto al origen, Q_{0q} , o a la media, Q_{1q} , o bien, descriptores basados en la Teoría de la Información

Técnicas basadas en distribuciones o estadísticos de segundo orden. Al igual que las anteriores se dividen en dos grupos: las que usan como descriptor de texturas este tipo de distribuciones (matrices de co-ocurrencia) y las que utilizan parámetros provenientes de ellas.

3.1.1. Parámetros estadísticos de primer orden.

Los parámetros más utilizados se formulan a continuación [Lowitz 83]. Como ya se ha comentado se obtienen a partir de momentos de distintos órdenes con respecto a un valor dado (media o cero), sus expresiones generales son:

$$Q_{0q} = \frac{1}{N} \sum_{i=0}^{r-1} (ih(i))^q$$

$$Q_{Xq} = \frac{1}{N} \sum_{i=0}^{r-1} [h(i) (i - X)^q]$$

A estos descriptores, en el contexto del análisis de textura, se les denomina estadísticos de primer orden debido a que se obtienen a partir de una distribución de primer orden de los niveles de gris de la imagen. Los parámetros utilizados son:

- * Media de los niveles de gris: $X = Q_{01}$
- * Varianza de los niveles de gris: $\sigma^2 = Q_{X2}$
- * Apuntamiento del histograma: $\delta = \frac{1}{\sigma^3} Q_{X3}$
- * Curtosis de histograma: $K = \frac{1}{\sigma^4} Q_{X4}$

La media y la varianza de los niveles de gris informan acerca del grado de uniformidad o regularidad de una región. Por último, la curtosis indica el grado de simetría del histograma. La mayor ventaja que posee el uso de estos descriptores es su simplicidad.

3.1.2. Parámetros basados en la Teoría de la Información.

Éstos también se obtienen del histograma, son:

- * Energía: $E = \frac{1}{N^2} \sum_{i=0}^{r-1} (h(i))^2$

$$* \text{ Sinergia: } S_y = \frac{1}{\sqrt{N}} \sum_{i=0}^{r-1} \sqrt{h(i)}$$

$$* \text{ Entropía: } E_t = \sum_{i=0}^{r-1} [h(i) \log(h(i))]$$

3.1.3. Métricas entre histogramas.

Este método de caracterización usa el histograma de niveles de gris de aquella región de la imagen que presenta la textura a analizar y se basa en el uso de métricas definidas entre histogramas. Esta técnica asume que un histograma es un vector de r coordenadas en un hiperplano r -dimensional, y se establece una función de distancia entre histogramas que caracteriza a la textura de interés como la distancia entre el histograma de la región que presenta la textura y un histograma patrón de referencia. Funciones de distancias empleadas con esta técnica son las siguientes [Lowitz 83]:

* Distancia Euclídea:

$$D^2(h, H) = \sum_{i=0}^{r-1} [h(i) - H(i)]^2$$

* Distancia de Bhattacharyya :

$$D_B(h, H) = \sum_{i=0}^{r-1} [\sqrt{h(i)} - \sqrt{H(i)}]$$

* Distancia de Mahalanobis:

$$D_M(h, H) = \sum_{i=0}^{r-1} \frac{(h(i) - H(i))}{h(i) * (1 - \frac{h(i)}{N}) + (H(i) * (1 - \frac{H(i)}{N}))}$$

Donde h es el histograma de la región de interés, H el histograma patrón, y N el número total de puntos de imagen de la región. Existe un histograma de referencia ampliamente utilizado, y que se define de la siguiente manera:

$$H = \{N/r, N/r, \dots, N/r\}$$

Este histograma presenta la característica de ser un histograma de entropía mínima para una región de N puntos de imagen.

Se ha propuesto un método de caracterización de texturas que podría catalogarse como un híbrido entre las dos metodologías anteriores [Lowitz 84]. Éste utiliza dos descriptores, llamados módulo del histograma local $\|h\|$ y fase del histograma local $\phi(h)$, que se calculan en base a las siguientes expresiones:

$$* \quad \|h\| = \sum_{i=0}^{r-1} [(h(i) - H(i)) * (\log(h(i)) - \log(H(i)))]$$

$$* \quad \phi(h) = j, h(j) \geq h(i) \forall i \neq j$$

Se puede decir que el descriptor $\|h\|$ es la entropía de la función distancia de Mahalanobis D_M entre el histograma h y el histograma H definido anteriormente.

3.1.4. Distribuciones de segundo orden: Matrices de Co-ocurrencia.

Se trata de distribuciones citadas frecuentemente en la literatura. Este tipo de

matrices reflejan distribuciones de frecuencias de aparición de relaciones espaciales entre los niveles de gris que dan lugar a los estadísticos de segundo orden, que son sensibles a las relaciones espaciales entre los niveles de gris de la textura. Su uso frecuente se debe principalmente a la conjetura de Julesz que afirma que la visión humana utiliza estadísticos de segundo orden para discriminar texturas [Julesz 75]. Julesz y Gagolowicz evaluaron la veracidad de esta afirmación experimentando con una batería de texturas ejemplo, sin embargo se ha criticado esta experiencia debido a que estos no utilizaron texturas naturales.

Una matriz de co-ocurrencia representa una distribución de segundo orden, en donde se contabiliza el número de veces que un par de niveles de gris que cumplen una determinada relación espacial, de ahí la clasificación de segundo orden, se da en la región de la imagen estudiada. Formalmente, una matriz de co-ocurrencia se define de la siguiente manera:

Sea una imagen digital, $I: L_x * L_y \rightarrow G$, con dominios espaciales horizontal y vertical $L_x = \{0, 1, \dots, dx-1\}$, $L_y = \{0, 1, \dots, dy-1\}$ respectivamente, y niveles de gris $r = \{0, 1, \dots, m-1\}$. Sea d la distancia que separa a dos puntos de la imagen, cuyas posiciones son (x_1, y_1) y (x_2, y_2) y cuyos niveles de gris son s y t . Cuando $d=1$ significa que los puntos son adyacentes, $d=2$ significa que los puntos están separados por otro punto de la imagen, y así sucesivamente. Tomando las direcciones dadas por los ángulos $\theta = \{0^\circ, 45^\circ, 90^\circ \text{ y } 135^\circ\}$ y una distancia d , obtenemos 4 matrices de co-ocurrencia, $P_0, P_{45}, P_{90}, P_{135}$ que se definen de la siguiente manera:

$$P_{0^\circ} = [p(s, t)] , s=0, \dots, r-1 \wedge t=0, \dots, r-1$$

Donde $p(s,t)$ representa al número de pares de puntos que cumplen las dos

propiedades siguientes:

1. $I(y_1, x_1) = s \wedge I(y_2, x_2) = t$
2. $x_1 - x_2 = d \wedge y_1 = y_2$

En cuanto a las demás matrices, éstas se definen de manera análoga; cambiando sólo la relación espacial que se debe cumplir para cada caso, así por ejemplo, para P_{45} se tendría que cumplir la siguiente relación espacial:

$$y_1 - y_2 = d \wedge x_1 - x_2 = -d$$

Estos estadísticos de segundo orden son inherentemente no invariantes a rotaciones. Para salvar esta limitación direccional se establece la llamada matriz de co-ocurrencia generalizada P , que se calcula a partir de la suma de las matrices anteriores, esto es:

$$P = \sum_{\Phi_i} P_{\Phi_i}$$

Al igual que ocurría con los histogramas locales, la caracterización de texturas mediante matrices de co-ocurrencia se puede establecer a partir de ellas directamente, o bien, por medio de parámetros que se calculan a partir de ellas. La descripción de estas dos técnicas se hará siguiendo el orden cronológico en que fueron utilizadas, es decir, primero se describirá la utilización de parámetros provenientes de las matrices de co-ocurrencia, y seguidamente se procederá a la descripción de su utilización como descriptores en sí mismas.

3.1.4.1. Descriptores basados en las Matrices de Co-ocurrencia.

Esta técnica consiste en el cálculo de diversos descriptores a partir de las matrices de co-ocurrencia de la región que presenta la textura de interés. En el contexto del análisis de texturas se les denomina estadísticos de segundo orden debido a que se obtienen a partir de una distribución de segundo orden. Concretamente Haralick [Haralick 83] ha propuesto catorce descriptores basados en la Teoría Estadística y de la Información, no teniendo algunos de ellos un significado visual preciso. Aún así, podemos agruparlos de la siguiente forma [Calvin 90]:

1. Parámetros que caracterizan aspectos visuales de la textura: contraste, correlación y segundo momento angular.
2. Parámetros estadísticos: covarianza, momento de diferencias inversa, media del sumatorio, varianza del sumatorio, varianza de las diferencias, y coeficiente máximo de correlación.
3. Parámetros basados en la Teoría de la Información: entropía, entropía del sumatorio, y entropía de las diferencias.

Para establecer las expresiones matemáticas de estos descriptores debemos primeramente definir la matriz de co-ocurrencia normalizada:

$$P_N = [P'(s, t)] = \frac{P(s, t)}{M}$$

Donde M es la constante de normalización que normalmente es el número de puntuaciones de la matriz, esto es:

$$M = \sum_{s=0}^{r-1} \sum_{t=0}^{r-1} P(s, t)$$

También se deben establecer las matrices de probabilidades marginales P_x y P_y como:

$$P_x = [P_x(t)] = \sum_{s=0}^{r-1} P'(s, t), t=0, \dots, r-1$$

$$P_y = [P_y(s)] = \sum_{t=0}^{r-1} P'(s, t), s=0, \dots, r-1$$

De los catorce descriptores propuestos los utilizados más frecuentemente en sistemas de inspección automática son cinco:

* Momento angular de segundo orden: $B_N = \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P_M(i, j)^2$

Este descriptor, al que algunos autores también denominan energía, se utiliza para caracterizar el grado de uniformidad u homogeneidad de una textura. Tiende a tomar valores pequeños cuando las entradas de P_M adoptan valores similares entre si, ocurriendo esto cuando se trata de una textura fina.

* Entropía: $B_E = - \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P_M(i, j) \log_2 [P_M(i, j)]$

Se trata de un descriptor que informa acerca del grado de disparidad de la textura. Toman valores altos cuando P_M posee valores altos y pequeños cuando los valores son dispares.

$$* \text{ Contraste: } B_{CO} = \sum_{n=0}^{r-1} n^2 \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P_M(i, j)^2; n=|i-j|$$

Caracteriza este descriptor el grado de dispersión de P_M . No teniendo una correlación con la percepción visual humana del contraste.

$$* \text{ Momento de la diferencia inversa: } B_H = \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} \frac{P_M(i, j)}{1+n^2}; n=|i-j|$$

Este descriptor mide el grado de homogeneidad local existente en P_M , de ahí que frecuentemente se le denomine por esta característica.

$$* \text{ Covarianza: } B_C = \frac{1}{\sigma_i \sigma_j} \sum_{i=0}^{r-1} (i-I) \sum_{j=0}^{r-1} (j-J) P_M(i, j)$$

Donde μ_i, μ_j son las medias y σ_i, σ_j las desviaciones típicas de los índices i y j , que están asociados a niveles de gris. Esta tiende a crecer a medida que los elementos de P_M tienden a adoptar valores similares.

Otros dos parámetros que se mencionan con cierta frecuencia en la literatura son:

$$* \text{ Autocorrelación: } B_A = \sum_{i=0}^{rc-1} \sum_{j=0}^{rc-1} ij P_M(i, j)$$

$$* \text{ Media de correlación I: } H_{XY1} = \sum_{i=0}^{r-1} \sum_{j=0}^{r-1} P_M(i, j) \log_2 [P_y(i) P_x(j)]$$

3.1.4.2. Caracterización por Matrices de Co-ocurrencia.

Esta técnica consiste en la interpretación de los pares de intensidades de una imagen como una muestra obtenida de un proceso aleatorio bidimensional. Las filas y columnas de una matriz de co-ocurrencia separan las muestras en varias clases basadas en las intensidades observadas. Por tanto, una matriz de co-ocurrencia tabula las frecuencias de aparición de cada clase [Zucker 81]. Este tipo de tablas se utiliza en Estadística, y se les denomina Tablas de Contingencia.

	1	.	j	.	r-1	
1	x_{11}	.	x_{1j}	.	$x_{1(r-1)}$	f_1
2	x_{21}	.	x_{2j}	.	$x_{2(r-1)}$	f_2
.	
i	x_{i1}	.	x_{ij}	.	$x_{i(r-1)}$	f_i
.
(r-1)	$x_{(r-1)1}$.	$x_{(r-1)j}$.	$x_{(r-1)(r-1)}$	$f_{(r-1)}$
	c_1	.	c_j	.	$c_{(r-1)}$	

Sea x_{ij} el número de veces que la variable A ha sido observada en la clase i, mientras que la variable B ha sido observada en la clase j. Si interpretamos las variables A y B como los puntos de la imagen que están a una distancia d, y las clases a las que ellas pertenecen como niveles de gris [0,r-1], la correspondencia entre matrices de co-ocurrencia y las tablas de contingencia es inmediata. Una matriz de co-ocurrencia no normalizada P es una tabla de contingencia con m clases horizontales y n clases

verticales, cumpliéndose $m=n=r$, siendo r el número de niveles de gris. Esta interpretación permite formular medidas estadísticas precisas de una textura a partir de sus matrices de co-ocurrencia.

La noción de textura, expresada por su matriz de co-ocurrencia, se expresa en base a qué se puede afirmar acerca de la variable B dadas las observaciones de A (y viceversa). Si la textura está aleatoriamente estructurada y la matriz de co-ocurrencia refleja esta textura; entonces las observaciones sobre A afectarán a las probabilidades de aparición de varias clases de B . Por otro lado, si la textura no se refleja en la matriz de co-ocurrencia; entonces las observaciones de A no afectarán a las probabilidades de B , es decir, A y B serán independientes. El grado de estructuración de una matriz de co-ocurrencia depende claramente de la relación espacial definida para su cálculo.

Se ha utilizado como característica de textura la propia matriz de co-ocurrencia, de forma que para saber si dos texturas pertenecen a la misma clase se comprueba si sus matrices asociadas representan distribuciones parecidas, es decir se mide su grado de ajuste, que teniendo en cuenta el significado estadístico de la matrices de co-ocurrencia se podrá realizar mediante un test de bondad de ajuste. El test Chi-Cuadrado, χ^2 , que se usa frecuentemente para comprobar el grado de ajuste de distribuciones empíricas con distribuciones teóricas, se ha empleado para tal fin [Zucker 81] y éste se realiza calculando:

$$\chi^2 = \sum_{i=0}^{r-1} \frac{(x_i - e_i)^2}{e_i}$$

Donde x_i es la frecuencia de aparición del valor i , y e_i la frecuencia teórica esperada de ese mismo valor.

3.1.5. Distribuciones de diferencias de niveles de gris.

Esta técnica se basa en las diferencias absolutas entre pares de niveles de gris, o de niveles de gris promedio [Weszka 76]. Una distribución de diferencias de niveles de gris se define de la siguiente manera: Sea una imagen discreta, I , de $\{0, 1, \dots, r-1\}$ niveles de gris, si definimos la relación espacial, d , dada por su módulo (distancia entre puntos de la imagen) y dirección θ , entonces dicha distribución establece las frecuencia de aparición de las diferencias en valor absoluto de los niveles de gris asociados a pares de puntos de la imagen I , que cumplen la relación espacial, d , definida. Por tanto, si tenemos r niveles de gris la distribución de diferencias absolutas entre intensidades la podemos representar a través de un vector, Z_d , de dimensión r .

Este tipo distribución se puede obtener a partir de la matriz de co-ocurrencia obtenida en base a la misma relación espacial establecida d . Por tanto, tiene el inconveniente que es inherentemente no invariante a transformaciones rotacionales y al igual que ocurría con las matrices de co-ocurrencia, dicho inconveniente se salva definiendo la distribución generalizada de diferencias absolutas de intensidades Z como aquella que se obtiene a partir de las P_d individuales calculando:

$$Z = \sum_{d=d_1}^{d_n} Z_d$$

Se han propuesto distintos parámetros de caracterización de texturas que se calculan a partir de estas matrices. Definimos la distribución normalizada de diferencias absolutas de intensidades como aquella que resulta de dividir cada elemento i de P_d por una constante de normalización M . Normalmente esta constante M es el número total

de diferencias absolutas de intensidades calculadas en la zona de la imagen a caracterizar. Parámetros utilizados a partir de estas distribuciones son:

* Contraste: $A_C = \sum_{i=0}^{r-1} i^2 Z(i)$

Este descriptor es el momento de orden dos con respecto al origen de la distribución de diferencias o el momento de inercia respecto al origen.

* Segundo momento angular: $A_N = \sum_{i=0}^{r-1} Z(i)^2$

Este mide el grado de disparidad existente en la distribución de diferencias. Toma valores pequeños cuando las frecuencias son similares y crece a medida que las frecuencias se hacen más dispares.

* Entropía: $A_E = - \sum_{i=0}^{r-1} Z(i) \log [Z(i)]$

Mide el grado de uniformidad de la distribución. Adopta su valor máximo cuando la distribución de diferencias es uniforme.

* Media: $A_M = \frac{1}{N_d} \sum_{i=0}^{r-1} i Z(i)$

A través de este descriptor se mide el grado de uniformidad de la textura; puesto que representa el valor medio de las diferencias encontradas.

3.2. PRODUCCIÓN DE DESCRIPTORES A PARTIR DE PROPIEDADES TOPOGRÁFICAS.

Desde un punto de vista matemático, esta técnica podría denominarse como

caracterización según propiedades morfológicas, donde las formas a analizar provienen de las primitivas tonales de la imagen. Esta metodología se ha aplicado fundamentalmente en el análisis de imágenes aéreas con el objetivo de detectar propiedades topográficas (valles, cadenas montañosas, cimas, etc). También se ha utilizado en el análisis de imágenes microscópicas, en biología e industria, con la finalidad de detectar microestructuras.

Este método consiste en representar texturas utilizando las propiedades topográficas encontradas en la imagen. El fundamento del método es la clasificación y agrupamiento posterior de áreas de la imagen en categorías topográficas. Cada categoría se representa utilizando conjunto básicos de funciones de los niveles de gris, y su posterior clasificación se realiza en base a relaciones estructurales entre categorías.

Desde un punto de vista teórico la caracterización de propiedades topológicas de una función bidimensional $I(x,y)$ se puede abordar a partir de las derivadas direccionales de primer y segundo orden calculadas en los puntos de la imagen. Concretamente ésta se puede realizar a través de los siguientes descriptores:

- $\nabla I(x,y)$ Gradiente de la función $I(x,y)$.
- $\|\nabla I(x,y)\|$ Módulo del Gradiente de $I(x,y)$.
- $\omega^{(1)}$ Vector unitario en la dirección en la que la derivada adopta el valor máximo.
- $\omega^{(2)}$ Vector unitario ortogonal a $\omega^{(1)}$.
- λ_1 Valor de la derivada segunda en la dirección $\omega^{(1)}$.
- λ_2 Valor de la derivada segunda en la dirección $\omega^{(2)}$.
- $\nabla I(x,y) \cdot \omega^{(1)}$ Valor de la derivada primera en la dirección $\omega^{(1)}$.

$\nabla I(x,y) \cdot \omega^{(2)}$ Valor de la derivada primera en la dirección $\omega^{(2)}$.

En función de estos parámetros se puede establecer la siguiente caracterización teórica de los siguientes elementos topográficos:

Cima $\| \nabla I(x,y) \| = 0, \lambda_1 < 0, \lambda_2 < 0$

Cráter $\| \nabla I(x,y) \| = 0, \lambda_1 > 0, \lambda_2 > 0$

Valle $\| \nabla I(x,y) \| \neq 0, \lambda_1 > 0, \nabla I(x,y) \cdot \omega^{(1)} = 0$
 \vee

$\| \nabla I(x,y) \| \neq 0, \lambda_2 > 0, \nabla I(x,y) \cdot \omega^{(2)} = 0$

Llanura $\| \nabla I(x,y) \| = 0, \lambda_1 = 0, \lambda_2 = 0$

Ladera $\nabla I(x,y) \cdot \omega^{(1)} \neq 0, \nabla I(x,y) \cdot \omega^{(2)} \neq 0$

Obviamente esta caracterización de elementos topográficos es teórica, en la práctica se han empleado distintas estrategias para tal fin, en esta línea destaca la propuesta de Haralick [Haralick 83] que consiste en la detección de valles y cadenas de picos (cordilleras) utilizando polinomios de tercer grado, cuya forma general es:

$$k_1 + k_2 r + k_3 c + k_4 r^2 + k_5 r c + k_6 c^2 + k_7 r^3 + k_8 r^2 c + k_9 r c^2 + k_{10} c^3$$

Siendo cada coeficiente k_i calculado en cada punto de la imagen mediante la convolución con los núcleos siguientes:

1/175

-13	2	7	2	-13
2	17	22	17	2
7	22	27	22	7
2	17	22	17	2
-13	2	7	2	-13

Núcleo asociado a k_1

1/420

31	-44	0	44	-31
-5	-62	0	62	5
-17	-68	0	68	17
-5	-62	0	62	5
31	-44	0	44	-31

Núcleo asociado a k_3

1/100

4	2	0	-2	-4
2	1	0	-1	-2
0	0	0	0	0
-2	-1	0	1	2
-4	-2	0	2	4

Núcleo asociado a k_5

1/420

31	-5	-17	-5	31
-44	-62	-68	-62	-44
0	0	0	0	0
44	62	68	62	44
-31	5	17	5	-31

Núcleo asociado a k_2

1/70

2	2	2	2	2
-1	-1	-1	-1	-1
-2	-2	-2	-2	-2
-1	-1	-1	-1	-1
2	2	2	2	2

Núcleo asociado a k_4

1/70

2	-1	-2	-1	2
2	-1	-2	-1	2
2	-1	-2	-1	2
2	-1	-2	-1	2
2	-1	-2	-1	2

Núcleo asociado a k_6

136

1/60					1/140				
-1	-1	-1	-1	-1	-4	-2	0	2	4
2	2	2	2	2	2	1	0	-1	-2
0	0	0	0	0	4	2	0	-2	-4
-2	-2	-2	-2	-2	2	1	0	-1	-2
1	1	1	1	1	-4	-2	0	2	4

Núcleo asociado a k_7

Núcleo asociado a k_8

1/140					1/60				
-4	2	4	2	-4	-1	2	0	-2	1
-2	1	2	1	-2	-1	2	0	-2	1
0	0	0	0	0	-1	2	0	-2	1
2	-1	-2	-1	2	-1	2	0	-2	1
4	-2	-4	-2	4	-1	2	0	-2	1

Núcleo asociado a k_9

Núcleo asociado a k_{10}

Básicamente, el método consiste en evaluar la primera y segunda derivada del polinomio anterior en cada punto de la imagen: primero, se calculan los coeficientes k_i del polinomio convolucionando con unos núcleos predefinidos, y en segundo lugar se evalúa dicho polinomio.

Este método pertenece a un conjunto de estrategias que asumen el Modelo de Faceta. Este modelo o estrategia establece que todo proceso de imagen tiene su interpretación final en base al tratamiento que se realiza en superficies de niveles de gris. Cada valor de gris en los puntos de la imagen son muestras con ruido de una

superficie fundamental que se asume a priori. Este enfoque requiere como paso previo a la realización de cualquier proceso la elección de una forma o patrón general ideal que se define en torno a cada punto de la imagen. Una vez adoptada la superficie patrón ideal, esta se debe adaptar en cada punto de la imagen mediante un ajuste que se realiza en base a la información que proporcionan los puntos vecinos al punto en cuestión. Una vez ajustados los puntos que configuran la superficie patrón se calculan aquellos parámetros, basados fundamentalmente en derivadas direccionales de distintos órdenes, que caracterizan las propiedades topográficas de interés.

3.3. GENERACIÓN DE DESCRIPTORES POR TRANSFORMACIONES LINEALES.

Esta técnica consiste en caracterizar cada textura en base a las respuestas que se producen cuando se convoluciona con núcleos lineales. Fundamentalmente, los núcleos empleados con esta estrategia son sensibles a determinados cambios espaciales de los niveles de gris [Bovick 89] [Rao 91] .

Probablemente, la aplicación más importante de esta técnica de caracterización de texturas fue la propuesta por Laws [Laws 80]. Este autor propuso el uso de un conjunto de núcleos de coeficientes enteros que al convolucionarlos con la imagen producían unos valores que utilizaba para calcular un descriptor que denominó "Energía Local de la Textura" (TE). Básicamente, este método de caracterización consta de dos pasos. El primero consiste en convolucionar la imagen a analizar con alguno de sus núcleos propuestos, esta es:

$$F(y, x) = A(y, x) * I(y, x) = \sum_{k=-a}^a \sum_{l=-a}^a A(k, l) I(y+k, x+l)$$

Donde $I(y, x)$ es la imagen original, $A(y, x)$ el núcleo de convolución, y $F(y, x)$ la imagen resultado. Valores nulos de $F(y, x)$ significa que en el entorno del punto (y, x) existe una región de textura uniforme. El segundo paso consiste en evaluar la función $E(y, x)$, que el autor denominó función de energía local de textura, siguiendo la expresión:

$$E(y, x) = \frac{1}{(2n+1)^2} \sum_{k=y-n}^{y+n} \sum_{l=x-n}^{x+n} |F(k, l) - M(y, x)|$$

Siendo $M(y, x)$ la media local de $F(y, x)$, dada por:

$$M(y, x) = \frac{1}{(2n+1)^2} \sum_{k=y-n}^{y+n} \sum_{l=x-n}^{x+n} F(k, l)$$

Entre las máscaras propuestas por Laws, las cuatro más utilizadas, por su alto grado de sensibilidad, son:

1	-4	6	-4	1	-1	0	2	0	-1
-4	16	-24	16	-4	-2	0	4	0	-2
6	-24	36	-24	6	0	0	0	0	0
-4	16	-24	16	-4	2	0	-4	0	2
1	-4	6	-4	1	1	0	-2	0	1
Núcleo R5R5					Núcleo E5S5				

-1	0	2	0	-1	-1	-4	-6	-4	-1
-4	0	8	0	-4	-2	-8	-12	-8	-2
-6	0	12	0	-6	0	0	0	0	0
-4	0	8	0	-4	2	8	12	8	2
-1	0	2	0	-1	1	4	6	4	1
Núcleo L5S5					Núcleo E5L5				

Para finalizar esta descripción se deben enunciar las características más importantes de las máscaras empleadas. La primera propiedad tiene que ver con el significado visual de estas; se tratan de núcleos que son sensibles a bordes, puntos, ondulaciones, etc. Las respuestas que producen tienen una alta dependencia de las dimensiones de los núcleos empleados. Por último la segunda propiedad es que no son invariantes a rotaciones y cambios de escala.

Otras técnicas ensayadas se basan en la utilización de núcleos que son sensibles a cambios en las frecuencias de los niveles de gris. Concretamente permiten obtener la frecuencia contenida en varias bandas, mediante simples operaciones de sumas y restas. A continuación, para ilustrar este tipo de núcleos, se describen algunos de ellos para el caso unidimensional:

$$+1 \ +1 \ +1 \ +1 \ -1 \ -1 \ -1 \ -1$$

$$+1 \ +1 \ -1 \ -1 \ +1 \ +1 \ -1 \ -1$$

$$+1 \ -1 \ +1 \ -1 \ +1 \ -1 \ +1 \ -1$$

3.4. DESCRIPTORES DE FOURIER.

Usualmente, el concepto de textura se asocia con la noción de regularidad en el sentido de que una textura se modeliza como un conjunto de elementos de formas similares espaciados regularmente. La Transformada de Fourier es una técnica que frecuentemente se utiliza para caracterizar el grado de regularidad que presenta una imagen, desarrollándose esta en el dominio de las frecuencias espaciales.

Una técnica ampliamente referenciada de descripción de texturas basada en la Transformada de Fourier utiliza el espectro de potencia [D'Astous 84]. Este método básicamente consiste en calcular, primero, la Transformada de Fourier, $F(u,v)$, que en el dominio discreto (Transformada discreta de Fourier) sigue la expresión:

$$F(u, v) = \frac{1}{N} \sum_{y=0}^{N-1} \sum_{x=0}^{N-1} I(y, x) e^{-i2\pi \frac{(yu+xv)}{N}} \quad 0 \leq u, v \leq N-1$$

Seguidamente se obtiene el espectro de potencia de la imagen, este viene dado por la función módulo de $F(u,v)$, es decir:

$$P(u, v) = (\{Re[F(u, v)]\}^2 + \{Im[F(u, v)]\}^2)^{1/2}$$

A través de la función $P(u,v)$ se pueden describir el grado de grosor y de direccionalidad de la textura que presenta la imagen I . Concretamente, si los valores máximos de $P(u,v)$ se concentran cerca del origen, $(u,v)=(0,0)$, entonces se trata de una textura con un alto grado de grosor, en el caso contrario, es decir, cuando $P(u,v)$ presenta valores significativos en la zona de altas frecuencias, entonces se trata de una textura fina (bajo grado de grosor). La direccionalidad de la textura se manifiesta en $P(u,v)$ cuando sus máximos valores tienden a seguir una dirección determinada.

Además, se cumple que la tendencia direccional manifestada en $P(u,v)$ es perpendicular a la que se manifiesta en la imagen original.

En el problema de detección que nos ocupa se ha utilizado la siguiente caracterización a partir del espectro de potencia. Dependiendo del tipo de textura, se seleccionaba un tamaño de ventana cuadrada de imagen, y a partir de esta elección se procede, para cada ventana, a calcular el sumatorio de los armónicos al cuadrado contenidos en unas determinadas bandas. Concretamente se utilizaron tres bandas de frecuencias, estas son:

$$1. \text{ Banda } 0-8: EB_1 = \sum_{u=0}^8 \sum_{v=0}^8 (P(u, v))^2$$

$$2. \text{ Banda } 0-15: EB_2 = \sum_{u=0}^{15} \sum_{v=0}^{15} (P(u, v))^2$$

$$3. \text{ Banda } 8-15: EB_3 = \sum_{u=8}^{15} \sum_{v=8}^{15} (P(u, v))^2$$

3.5. OBTENCIÓN DE DESCRIPTORES MEDIANTE TRANSFORMACIONES ALGORÍTMICAS.

Esta técnica parece tener capital interés en transformaciones no convencionales no lineales de datos sensoriales, especialmente datos visuales, en problemas de síntesis de sistemas. Una ilustración de convolución generalizada no algebraica, que se corresponde con una transformación algorítmica no lineal de datos retinales estáticos, se describe de la siguiente manera:

Sean C y P áreas central y periférica respectivamente definidas entorno a un

punto (y,x) de una imagen. La inhibición lateral simbólica requiere la definición de un proceso A en la región C y un proceso B en P. Entonces, P inhibe a C de acuerdo a una regla de decisión que tiene en cuenta los resultados de A y B.

Este sencillo, pero poderoso algoritmo para la inhibición lateral simbólica es tal que los procesos A y B son selectores del máximo en las regiones en donde operan cada uno. Esto es:

Proceso A Seleccionar $\text{Max}(C) = C_m$

Proceso B Seleccionar $\text{Max}(\text{Abs}(P)) = P_m$

Si $C_m(y,x)$ es el valor máximo de las señales presentes en el área central definida entorno a (y,x) , y si $P_m(y,x)$ se corresponde con el máximo de los valores absolutos de la periferia de (y,x) , entonces se ejecuta la siguiente regla de decisión que da lugar a la función de salida $F(y,x)$.

"Si" $(C_m(y,x) > P_m(y,x))$ "Entonces"

$$F(y,x) = C_m(y,x)$$

"Si no"

$$F(y,x) = P_m(y,x)$$

"Fin si"

Este tipo de núcleo ha producido buenos resultados en ciertas clases de texturas debido a que proporciona primero un criterio de crecimiento de regiones tras varias pasadas sobre la imagen original y después sobre sucesivas imágenes transformadas.

3.6. DESCRIPTORES SUPERVISADOS.

Estas técnicas se caracterizan por el uso de algún elemento supervisor en sus etapas iniciales, con el objeto de disponer de un patrón de comportamiento de las texturas de interés, que posteriormente será utilizado en la fase de detección. Este patrón generalmente se construye utilizando un conjunto de descriptores, como los descritos en apartados anteriores, calculados en un conjunto de áreas locales de la imagen a analizar. Todo proceso supervisado de detección se desarrolla en dos etapas, esta son:

1. Adquisición supervisada del patrón de comportamiento.
2. Proceso de detección por diferencia de comportamiento.

Por tanto, toda técnica supervisada de detección se construye en base a las siguientes especificaciones:

1. Cómo se seleccionan las áreas locales de interés.
2. Cómo se representan las texturas que presentan dichas áreas.
3. Cómo se realiza el proceso de detección en base al patrón de comportamiento.

La justificación del uso de las técnicas supervisadas en los problemas de caracterización de texturas se encuentra en los inconvenientes potenciales que presentan técnicas no supervisadas. Si llamamos a los descriptores obtenidos mediante un proceso de supervisión, "descriptores aprendidos" , debido a que representan un comportamiento relevante y han sido obtenidos directa o indirectamente a través de la interacción

humana, los inconvenientes de los descriptores utilizados en procesos no supervisados, descriptores no aprendidos, se resumen en:

Particularidad del tipo de característica. Este inconveniente se pone de manifiesto fundamentalmente en la caracterización mediante respuesta ante núcleos lineales. Normalmente los núcleos no aprendidos se derivan de vectores que representan promedios ponderados centrados, derivadas de primer grado simétricas (generalmente utilizadas para detectar bordes), y derivadas de segundo grado (generalmente utilizadas para detectar "picaduras" que formalmente se modeliza mediante la detección de máximos y mínimos). Sin embargo, las escenas naturales suelen estar altamente texturadas presentando características más complejas a las que se detectan con los núcleos no aprendidos.

Particularidad del número de patrón. Cada núcleo no aprendido es sensible a una determinada característica de textura. Cuando se trata de una textura compleja, formada por varias características, generalmente no tienen un buen comportamiento.

Además existen dos problemas que se plantean tanto en los métodos supervisados como en los no supervisados y que dificultan la caracterización, concretamente:

Dependencia dimensional. Existe un alto grado de dependencia entre la dimensión de un núcleo no aprendido y la respuesta de este. Esto es, incluso en el caso de detección de características típicas (bordes, picaduras, etc) se tendría que elegir unas dimensiones del núcleo sensible acorde con el tamaño de la

característica a detectar.

No invarianza. Muchos de los descriptores no aprendidos no son invariantes a transformaciones afines: translaciones, rotaciones y cambios de escala.

Qué justifican el uso de técnicas adaptativas de caracterización. Estas se fundamentan en el uso de algún método que permite adaptar la definición a priori de un determinado descriptor, por ejemplo los coeficientes de un núcleo de convolución, a las peculiaridades de la textura de interés. En esta línea, You [You 93] propone una técnica para adaptar los núcleos propuestos por Laws [Laws 80]; de forma que éstos produzcan unas respuestas que permitan clasificar texturas, siendo esta clasificación invariante a posibles rotaciones y cambios de escala de la imagen.

Las estrategias supervisadas, en los problemas de inspección automática, independientemente de su uso como solución final al problema, son utilizadas generalmente porque permiten obtener información sobre el comportamiento de los descriptores utilizados. Básicamente, permiten conocer cómo se distribuyen en el espacio de descriptores empleado, informando acerca de la posible existencia de tendencias de agrupamiento de los descriptores asociados a las texturas de interés. Este tipo de información es fundamental para establecer un aspecto importante de los procesos de detección, que consiste en definirlos como de carácter global, la discriminación entre las texturas se establece en base a información obtenida en toda la imagen, o bien de carácter local, en los que la discriminación se realiza en base a diferencias de comportamiento en áreas locales de la imagen utilizando esquemas de gradientes.

La técnica supervisada empleada consiste en obtener los valores que adoptan los descriptores, descritos en los apartados anteriores, en zonas que presentaban texturas visualmente diferentes. Estas zonas se determinaban mediante un proceso manual que consiste en guiar una ventana sobre la imagen a analizar hasta las áreas de interés. Más concretamente, secuencialmente el método consta de los siguientes pasos:

1. Especificación de las áreas locales de interés. A través de una ventana cuadrada de dimensión 31 se seleccionaban zonas con diferentes texturas.
2. Para un conjunto de muestras de ventanas con un mismo tipo de textura, se calculaban los valores que adoptaban un conjunto dado de descriptores, obteniéndose para cada uno de ellos su valor medio. De esta manera se obtiene un punto centroide que representa a la clase de textura seleccionada en el espacio de los descriptores. Análogamente se obtiene los puntos centroides que representaba a las otras clases de texturas.
3. Para cada "área problema" se calculan los valores de los descriptores utilizados y se calculaba la distancia a cada uno de los puntos centroides.
4. La textura asociada al "área problema" se identifica con la clase de textura asociada al punto centroide más próximo.

Los resultados obtenidos con este esquema no fueron buenos fundamentalmente debido a que los cambios en la iluminación y el ruido influían considerablemente. Otro inconveniente que presentaba el esquema era su alta dependencia de las áreas locales elegidas. Por todo ello, no es recomendable asumir este esquema supervisado como método de detección.

Aplicado el esquema anterior propuesto a descriptores individuales y analizando los valores que estos adoptaban, se pusieron de manifiesto las siguientes propiedades:

1. El tipo de textura afectaba considerablemente a todos los descriptores utilizados.
2. Incluso para un mismo tipo de textura, y en zonas clasificadas visualmente como pertenecientes a un mismo tipo, no existía un comportamiento uniforme de los descriptores

Otro esquema supervisado que se aplicó consiste en:

1. Elegir áreas locales catalogadas como no defectuosas.
2. En cada una de ellas se calcula la media M de sus niveles de gris.
3. En cada una de ellas se obtienen un núcleo de convolución. Este se obtiene de la siguiente manera: El núcleo K del cada área tenía las mismas dimensiones que esta. Si (y_0, x_0) y (y_1, x_1) son las coordenadas del vértice superior izquierdo y del vértice inferior derecho respectivamente, entonces el K se define de la siguiente manera:

"Para" $y=y_0$ hasta y_1 "Hacer"

"Para" $x=x_0$ hasta x_1 "Hacer"

"Si" $I(y,x) > M$ "Entonces" $K(y-y_0, x-x_0) = 1$

"Sino" $K(y-y_0, x-x_0) = -1$

"Fin Para"

"Fin Para"

4. En cada "área problema" se convoluciona con cada uno de los núcleos, obteniéndose un vector de descriptores que representaba al área.

4.1. COMPORTAMIENTO DE LOS DESCRIPTORES UTILIZADOS.

En esta sección se describe el comportamiento de las distintas técnicas de caracterización de texturas utilizadas en el marco de la estrategia propuesta y para los materiales inspeccionados, recordando que para cada descriptor se genera una imagen de característica y a continuación una imagen de distancias sobre la cual se efectúa el diagnóstico. Como se podrá observar, y como era de esperar, no todos los descriptores probados son apropiados para la detección de defectos en los materiales analizados, no debiéndose concluir acerca de ellos que no son utilizables en general, probablemente para materiales de otra naturaleza éstos tengan un comportamiento mejor. Sobre el conjunto de descriptores que poseen un buen comportamiento hay que decir que algunos de ellos, por ejemplo estadísticos de primer orden, han sido considerados tradicionalmente como de bajo poder discriminante en la clasificación de texturas.

Para contrastar la idoneidad de los distintos descriptores se ha experimentado con un conjunto de pieles que presentaban defectos de distinta naturaleza. Se ha umbralizado la imagen de diferencias que cada uno genera; específicamente cada imagen de este tipo se ha segmentado en dos clases (zona defectuosa y zona no defectuosa) utilizando un umbral U calculado a partir de los valores generados en la imagen de diferencias, concretamente:

$$U = \mu + k\sigma$$

Siendo μ y σ la media y la varianza respectivamente de los valores producidos en la imagen de diferencias y k un valor real positivo que se hace variar de forma decreciente, dando lugar así a valores de U cada vez más pequeños y produciendo por

tanto sucesivos diagnósticos que nos informan sobre el grado de cumplimiento de las siguientes propiedades que un buen descriptor debe poseer:

- 1. Uniformidad de comportamiento:** Las zonas no defectuosas tendrán un comportamiento similar con respecto al descriptor, por tanto tendrán asociadas en la imagen de diferencias valores pequeños y muy similares.
- 2. Sensibilidad:** La frontera entre un área defectuosa y otra que no lo es debe producir unos valores altos, en comparación con los generados por las zonas no defectuosas, en la imagen de distancias.
- 3. Fiabilidad:** El descriptor tendrá un comportamiento mejor a medida que el rango de valores asociado a las zonas sin imperfecciones esté más separado del producido por las áreas que presentan defectos.

Para ilustrar las pruebas realizadas se presentan algunos ejemplos de resultados.

En estas ilustraciones se han utilizado dos imágenes de pieles de cerdo que presentan defectos de distinta naturaleza e intensidad visual. Antes de pasar a mostrar dichos ejemplos se ha de especificar que el tamaño de ventana de trabajo de 31 y las diferencias se han calculado entre ventanas situadas a una distancia de 15.

4.1.1. Estadísticos de primer orden.

Pertenecientes a esta categoría se han probado los siguientes descriptores: media, varianza, curtosis y apuntamiento, manifestando un buen comportamiento sólo los dos primeros. La media tiene un buen comportamiento cuando el defecto se manifiesta como transiciones de zonas claras a oscuras, o viceversa, un ejemplo de defecto que se manifiesta de esta manera son las manchas. La varianza, en cambio, se manifiesta como un buen descriptor cuando el defecto produce una alteración estructural, a veces de dimensiones muy pequeñas como por ejemplo picaduras y otras de dimensiones considerables como por ejemplo raspaduras y cicatrices, que dan lugar a aglomeraciones de puntos con intensidades muy altas en la imagen. En cuanto a los descriptores que no manifiestan tener un buen comportamiento, curtosis y apuntamiento, ambos presentan una excesiva sensibilidad en áreas que presentan puntos con intensidades extremas, 0 y 255, debido a ruidos en la adquisición o fallos en la placa de visión. También éstos manifiestan una escasa sensibilidad en defectos muy evidentes. Seguidamente se ilustran estos comportamientos presentando el diagnóstico producido por cada uno de los descriptores tomando como umbral de corte en la imagen de diferencias el resultante de evaluar la expresión: $\mu + 1.5\sigma$.




Ilustración 4.1. Diagnóstico producido por el parámetro media tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.2. Diagnóstico producido por el parámetro varianza tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.3. Diagnóstico producido por el parámetro curtosis tomando como umbral $U = \mu + 0.1\sigma$.




Ilustración 4.4. Diagnóstico producido por el parámetro apuntamiento tomando como umbral $U = \mu + 3\sigma$.

4.1.2. Descriptores basados en la Teoría de la Información.

Pertenecientes a esta categoría se han probado los siguientes: entropía, sinergia y energía, manifestando un buen comportamiento los dos últimos descriptores mencionados. La energía y sinergia manifiestan un comportamiento análogo en defectos estructurales, similar al manifestado por la varianza pero con una mayor fiabilidad en los diagnósticos generados por esta última. En cuanto a la entropía, ésta se manifiesta como un descriptor cuyos valores no están correlacionados con áreas buenas y malas, produciendo por tanto unos diagnósticos donde los defectos no son detectados totalmente y dotados de muchos espúreos (áreas locales de dimensiones reducidas diagnosticadas como defectos sin serlo realmente). Seguidamente se ilustra lo descrito sobre el comportamiento de estos descriptores.




Ilustración 4.5. Diagnóstico producido por el parámetro energía tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.6. Diagnóstico producido por el parámetro sinergia tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.7. Diagnóstico producido por el parámetro entropía tomando como umbral $U = \mu + 3\sigma$.

4.1.3. Métricas entre histogramas.

Recordando que esta técnica consiste en caracterizar las texturas mediante la utilización de funcionales que miden el grado de proximidad entre dos funciones (que en el caso que nos ocupa representan distribuciones de probabilidad), se ha de decir que se han probado las funciones de distancia: euclídea, Bhatthacharyya y Mahalanobis, también se ha utilizado el test estadístico χ^2 . Para todo estos casos se ha usado como distribución de referencia la uniforme, consistiendo por tanto la caracterización en la aplicación de cada uno de los funcionales anteriores entre el histogramas de cada área local h y el histograma h_0 asociado a la distribución uniforme.

En cuanto a las pruebas realizadas, hay que destacar que la distancia euclídea y el test χ^2 han proporcionado buenos y similares resultados. Dicho comportamiento se resume de la siguiente manera: en primer lugar, estos funcionales son sensibles tanto a defectos que se manifiestan como transiciones de zonas claras a oscuras (por ejemplo manchas), como estructurales (cicatrices, agujeros, etc), en segundo lugar presentan un comportamiento similar al producido por la varianza y energía anteriormente mencionados. Con respecto a los comportamientos de las distancias de Bhatthacharyya y Mahalanobis, éstos se manifiestan como poco sensibles a la presencia de defectos generando además muchos diagnósticos erróneos.




Ilustración 4.8. Diagnóstico producido por el parámetro distancia euclídea tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.9. Diagnóstico producido por el parámetro test χ^2 tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.10. Diagnóstico producido por el parámetro distancia Bhatthacharyya tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.11. Diagnóstico producido por el parámetro distancia de Mahalanobis tomando como umbral $U = \mu + 3\sigma$.

4.1.4. Estadísticos de segundo orden (Matrices de Co-ocurrencia).

Esta técnica consiste en caracterizar la textura mediante parámetros que se obtienen a partir de distribuciones estadísticas de segundo orden (matrices de co-ocurrencia). El comportamiento manifestado por este tipo de descriptores ha sido, en general, de una sensibilidad a la presencia de defectos menor que a las manifestadas por los descriptores mencionados anteriormente y una tendencia mayor a la aparición de espúreos en los diagnósticos.

Un aspecto que debe comentarse referente a estos descriptores es la influencia de la distancia r , elegida para definir la relación espacial (recordamos que dicha relación espacial se define en base a dicha distancia r y a una dirección θ) que da lugar a la distribución estadística de segundo orden, representada por una matriz de co-ocurrencia. De las pruebas realizadas se desprende que el comportamiento es similar para distancias comprendidas entre 1 y 7, para distancias mayores la sensibilidad disminuye y aparecen espúreos en los diagnósticos, agravándose este comportamiento a medida que aumentamos r .

A continuación se ilustra lo descrito sobre esta técnica; los parámetros que se consideran son: energía, homogeneidad local e inercia.




Ilustración 4.12. Diagnóstico producido por el parámetro energía tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.13. Diagnóstico producido por el parámetro homogeneidad local tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.14. Diagnóstico producido por el parámetro inercia tomando como umbral $U = \mu + 3\sigma$.




Ilustración 4.15. Diagnóstico producido por el parámetro energía tomando distintas distancias en la matriz de co-ocurrencia. En la imagen superior derecha la distancia utilizada es 3, en la inferior izquierda es 9 y en la inferior derecha 13.

4.1.5. Núcleos lineales.

Pertenecientes a esta categoría se han probado los siguientes: máscaras de Laws y núcleos sensibles a cambios en la frecuencia de los niveles de gris. Las primeras no dieron buenos resultados en pieles de cerdo debido a que están orientadas a detectar elementos morfológicos de la textura a analizar (valles, cimas ...) a partir de los cuales se realiza la caracterización de la textura; en el problema planteado los elementos morfológicos que definen la textura (granulado en pieles de cerdo) aparecen de una forma más resaltada que los propios defectos y estos últimos no siempre se pueden describir mediante morfologías simples. Las máscaras de Laws probadas fueron la L31S31, R31R31, E31S31 y L31E31. Para pieles de vaca el resultado fue mejor, se probaron las mismas anteriormente mencionadas pero de dimensión 11.

En cuanto al segundo tipo de máscaras probadas, detectores de cambios de frecuencia en los niveles de gris, dieron buenos resultados los orientados a detectar cambios bajos en las frecuencias y además se adaptaban a formas comunes: flanco, valle, cima, etc... Ejemplo de tales núcleos, de dimensión 6, utilizados son:

1 1 1 -1 -1 -1	1 -1 -1 -1 -1 -1	1 1 1 1 1
1 1 1 -1 -1 -1	-1 -1 -1 -1 -1 -1	-1 -1 -1 -1 -1
1 1 1 -1 -1 -1	-1 -1 -1 -1 -1 -1	-1 -1 -1 -1 -1
1 1 1 -1 -1 -1	1 1 1 1 1 1	-1 -1 -1 -1 -1
1 1 1 -1 -1 -1	1 1 1 1 1 1	1 1 1 1 1
1 1 1 -1 -1 -1	1 1 1 1 1 1	1 1 1 1 1
K0	K1	K2

Seguidamente se ilustran estos comportamientos presentado el diagnóstico producido tomando como umbral de corte en la imagen de diferencias el resultante de evaluar la expresión $\mu + 1.5\sigma$.




Ilustración 4.16. Diagnóstico producido por el parámetro máscara L31S31 tomando como umbral $U = \mu + 0.1\sigma$.




Ilustración 4.17. Diagnóstico producido por el parámetro máscara K1 tomando como umbral $U = \mu + 1.5\sigma$.




Ilustración 4.18. Diagnóstico producido por el parámetro máscara K2 tomando como umbral $U = \mu + 1.5\sigma$.

4.2. PROTOTIPOS DE SISTEMAS PARA LA DETECCIÓN DE DEFECTOS.

Los prototipos están basados en la metodología propuesta, y todos se definen en base a las siguientes especificaciones:

Dimensión de ventana.

Resolución de caracterización.

Descriptor.

Distancia de comparación.

La regla de decisión empleada para diagnosticar es común a todos los prototipos y se puede describir con el siguiente algoritmo.

Sean:

μ_C = media de los valores en la imagen de diferencias asociada al descriptor C.

σ_C = varianza de los valores en la imagen de diferencias asociada al descriptor C.

"Para cada" descriptor C "hacer"

Obtener umbral de corte para el descriptor C.

"Si" $\sigma_C < 0.75\mu_C$ "entonces"

diferencias no significativas para el diagnóstico

"si no"

"Si" $\sigma_C > \mu_C$ "entonces"

$$U = \mu_C + 1.5\sigma_C$$

"si no"

$$U = \mu_C + 3.0\sigma_C$$

"fin si"

"fin si".

Producir la imagen de diagnóstico primario IDP_C asociada al descriptor C.

"Para todo" punto (i,j) de la imagen de diferencias "hacer"

"Si" $D(i,j) > U$ "entonces"

$$IDP_C(i,j) = 1$$

"sin no"

$$IDP_C(i,j) = 0$$

"fin si"

"fin para".

"fin para".

Producir la imagen diagnóstico final IDF.

"Para todo" descriptor C "hacer"

$$IDF = IDF \oplus IDP_C$$

"fin para".

* Pototipo DDPV1, destinado a la detección de defectos en pieles de cerdo, las características que lo definen son las siguientes:

Dimensión de ventana: 31x31.

Resolución de caracterización: máxima, es decir se caracteriza cada ventana de la dimensión anteriormente citada que se pueda establecer en la imagen a inspeccionar.

Descriptores: media y distancia euclídea.

Distancia de comparación: 15.

* Pototipo DDPV1, destinado a la detección de defectos en pieles de vaca, las características que lo definen son las siguientes:

Dimensión de ventana: 15x15.

Resolución de caracterización: máxima, es decir se caracteriza cada ventana de la dimensión anteriormente citada que se pueda establecer en la imagen a inspeccionar.

Descriptores: Núcleo L15L15, varianza, contraste.

Distancia de comparación: 7.

Los dos siguientes prototipos son variantes de los anteriores, la variación introducida consiste en la utilización del preproceso facilitador. El siguiente diagrama de bloques muestra las etapas de proceso que ambos realizan:




Figura 4.1. Diagrama de bloques utilizando el Proceso Facilitador.

Las dimensiones de área local utilizadas en el preproceso mencionado son:

Imágenes de pieles de cerdo: 55x55.

Imágenes de pieles de vaca: 31x31.

* Pototipo DDPC2, destinado a la detección de defectos en pieles de cerdo, las características que lo definen son las siguientes:

Dimensión de ventana: 31x31.

Resolución de caracterización: máxima, es decir se caracteriza cada ventana de la dimensión anteriormente citada que se pueda establecer en la imagen a inspeccionar.

Descriptor: media.

Distancia de comparación: 15.

* Pototipo DDPV2, destinado a la detección de defectos en pieles de cerdo, las características que lo definen son las siguientes:

Dimensión de ventana: 11x11.

Resolución de caracterización: máxima, es decir se caracteriza cada ventana de la dimensión anteriormente citada que se pueda establecer en la imagen a inspeccionar.

Descriptor: media.

Distancia de comparación: 5.

A continuación se pasa a ilustrar algunos ejemplos de resultados alcanzados por tales prototipos. Para los sistemas DDPC1 y DDPV1 en cada ilustración se presenta los resultados para dos imágenes de pieles, en las correspondientes a los sistemas DDPC2 y DDPV2 se presentan: en primer lugar la imagen original (imagen superior izquierda), en segundo lugar el resultado del preproceso (imagen superior derecha), en tercer lugar la imagen del parámetro media (imagen inferior izquierda) y por último el resultado del diagnóstico.




Ilustración 4.19. Ejemplo 1 de diagnósticos producidos por el sistema DDPC1.




Ilustración 4.20. Ejemplo 2 de diagnósticos producidos por el sistema DDPC1.




Ilustración 4.21. Ejemplo 3 de diagnósticos producidos por el sistema DDPC1.




Ilustración 4.22. Ejemplo 1 de diagnósticos producidos por el sistema DDPV1.




Ilustración 4.23. Ejemplo 2 de diagnósticos producidos por el sistema DDPV1.




Ilustración 4.24. Ejemplo 3 de diagnósticos producidos por el sistema DDPV1.




Ilustración 4.25. Ejemplo 1 de diagnóstico producido por el sistema DDPC2.




Ilustración 4.26. Ejemplo 2 de diagnóstico producido por el sistema DDPC2.




Ilustración 4.27. Ejemplo 3 de diagnóstico producido por el sistema DDPC2.




Ilustración 4.28. Ejemplo 1 de diagnóstico producido por el sistema DDPV2.




Ilustración 4.29. Ejemplo 2 de diagnóstico producido por el sistema DDPV2.




Ilustración 4.30. Ejemplo 3 de diagnóstico producido por el sistema DDPV2

CAPÍTULO 5.

Aportaciones y Conclusiones.



Las aportaciones de esta tesis se pueden dividir en dos categorías: las primeras de tipo teórico y las segundas de tipo práctico consecuencia de la aplicación de las anteriores.

5.1. APORTACIONES Y CONCLUSIONES CONCEPTUALES.

La principal consiste en el paradigma propuesto para formalizar los problemas de detección automática de defectos mediante técnicas de Visión Artificial. Este modelo teórico tiene por características principales:

1. Al contrario que el esquema computacional asumido generalmente en Visión Artificial de pirámide invertida, nuestro modelo contempla la utilización de un espacio de representación de mayor dimensión que el espacio de datos inicial, implicando por tanto una expansión de los grados de libertad del problema.
2. Su marcado carácter de bajo nivel, entendiéndose por esto que se basa en procesos de imagen de bajo nivel, en contraposición a los casos de sistemas que necesitan a priori un aprendizaje sobre el material a analizar.
3. Están perfectamente definidos todos aquellos aspectos que deben especificarse para su aplicación a un problema dado, éstos se refieren a:
 - Dimensión de área local.
 - Conjunto de descriptores.
 - Medición del grado de homogeneidad local.

Otras aportaciones realizadas y relacionadas con las especificaciones anteriores son las siguientes:

1. Tras un estudio de la influencia del tamaño de la ventana de trabajo en la potencialidad de las características para discriminar zonas se ha desarrollado una metodología que establece de forma automática el tamaño óptimo del área de la ventana local o tamaño del núcleo de convolución a utilizar en el proceso de detección. En este punto se debe decir que éste es un aspecto que normalmente no es contemplado, desde un punto de vista formal, en las distintas propuestas de sistemas de inspección visual automática.

2. Como consecuencia del estudio de comportamiento de las distintas técnicas de caracterización de texturas, se propone un esquema de diagnóstico novedoso; éste se realiza en el espacio de diferencias y no en el espacio de los descriptores que es el utilizado tradicionalmente. La justificación de ello se debe a que las imágenes de diferencias son más inmunes a condiciones ambientales adversas (iluminación no uniforme y ruido).

3. Para medir el grado de homogeneidad local se han estudiado distintos funcionales de distancia, proponiendo funcionales de bajo coste computacional y alta sensibilidad: diferencias relativas de características individuales. Este tipo de diferencias permiten detectar un amplio abanico de defectos que se manifiestan con una intensidad visual variable mediante reglas de decisión simples.

La última aportación se refiere a la técnica de preproceso desarrollada que hemos llamado proceso facilitador, consistente en el efecto multiplicador de las salidas de dos procesos locales. Esta técnica de carácter local se manifiesta como un detector de flancos que aplicada a las texturas analizadas produce una enfatización de una amplia variedad de defectos a detectar, facilitando así su localización. Además este preproceso se puede implementar mediante una red de elementos de cómputo paralela.

5.2. APORTACIONES Y CONCLUSIONES PRÁCTICAS.

La primera de ellas consiste en el planteamiento de una estrategia general destinada a permitir la especificación adecuada de los aspectos anteriormente citados y por tanto la construcción de sistemas de inspección visual automática para distintos tipos de materiales: pieles, maderas, tejidos, plásticos, celulosa, etc. Concretamente se han diseñado prototipos de sistemas para la detección de defectos en pieles de cerdo y vaca. De los resultados obtenidos se desprende:

1. El modelo de detección planteado es independiente del tipo de texturas, ya que las que presentan estos materiales difieren considerablemente.
2. Al estar basados en descriptores texturas que tradicionalmente han sido considerados como de bajo poder discriminante, se pone de manifiesto la conveniencia de la detección en el dominio de las imágenes de diferencias. Además son de fácil cálculo y susceptibles de ser implementados mediante algoritmos rápidos.
3. Al estar adquiridas las imágenes procesadas en condiciones de iluminación asumibles

en una planta de producción, se pone de manifiesto su viabilidad práctica.

De la experimentación realizada con los materiales analizados y utilizando la metodología que se propone, se puede concluir que la detección automática de defectos, utilizando un sistema de visión artificial, es difícil debido a que el proceso humano de inspección tiene un origen multisensorial (a veces se utiliza información táctil y en muchas ocasiones se realiza mediante distintas observaciones del material) y también por que algunos defectos, que no son predecibles a priori, necesitan requerimientos de iluminación especiales para ser percibidos por un sistema cámara-computador. Sin embargo, cuando los defectos a localizar se manifiestan con un cierto grado de intensidad visual, éstos se pueden localizar con un alto grado de fiabilidad mediante algoritmos rápidos como los propuestos.

Para finalizar mencionar que se ha realizado una revisión exhaustiva de los métodos empleados en la detección de defectos en materiales diversos, no encontrado ninguna referencia al estudio de la detección de defectos en pieles. Dichas técnicas se han estudiado, implementado y probado para el caso de detección de defectos en pieles, analizando la bondad y funcionamiento de cada técnica propuesta.

5.3. LÍNEA FUTURA DE TRABAJO.

El trabajo de esta tesis y los algoritmos implementados se enmarcan dentro de las técnicas de bajo nivel, no se hace uso de elementos de memoria ni de sistemas de almacenamiento.

Una continuación de este trabajo puede realizarse en la vía de la construcción de

un sistema experto que partiendo de los descriptores calculados vaya construyendo una base de datos referencial de clases de material y de defectos de forma que el sistema vaya "aprendiendo" y adquiriendo "experiencia" de los materiales a estudiar.

Por otra parte, se propone el estudio y realización de una base de inferencias que se alimente con los algoritmos de cálculo de descriptores y con las reglas de decisión, para que el sistema sea capaz para cada clase de material problema elegir los algoritmos de cálculo de descriptores y las reglas de decisión más adecuadas para este tipo de material.

Una de las ventajas del sistema desarrollado es su posible consideración como un subsistema parte de un sistema robótico más completo, en el que existan otros elementos sensores que proporcionen otras pistas multisensoriales y donde puedan existir manipuladores que interactúen entre si.

REFERENCIAS.

- [Ade 83]** Ade, F. "Application of principal component analysis to the inspection of industrial goods". Applications of Digital Image Processing, vol. 397, pag. 216-223, SPIE 1983.
- [Borghesi 84]** Borghesi, M., Cantoni, V. y Diani, M. "An Industrial Application of Texture Analysis". 7th International Conference on Pattern Recognition pag. 420-423, Montreal 1984.
- [Bovik 90]** Bovik, A., Clark, M. y Geisler, W. "Multichannel texture analysis using localized spatial filters". Transactions on Pattern Analysis and Machine Intelligence, vol. 12, pag. 55-73, IEEE Computer Society Press 1990.
- [Calvin 90]** Calvin, C., Gotlied y Kreyszig H. "Texture Descriptors Based on Co-occurrence Matrices". Computer Vision, Graphics and Image Processing, vol. 31, pag. 70-86, Academic Press Inc. 1990.
- [Candela 92A]** Candela, S., Muñoz, J., García, C. y Alayón F. "A CAST System for Visual Fault Detection Research". Lectures Notes in Computer Science, vol. 585, pag 402-411, Springer-Verlag, 1992.
- [Candela 92B]** Candela, S., Muñoz, J., Alayón, F. y García, C. "Un sistema de visión para la detección de defectos". Actas de la XVIII Conferencia Latinoamericana de Informática PANEL'92 pag. 240-247, Las Palmas de Gran Canaria 1992.
- [Candela 93]** Candela, S., García, C., Muñoz, J. y Alayón, F. "Facilitatory Process for Contrast Detection". Lectures Notes in Computer Science, vol. 720, pag. 627-630, Springer-Verlag 1993.
- [Connors 83]** Connors, R. "Identifying and Locating Surface Defects in Wood: Part of an Automated Lumber Processing System". Transactions on Pattern Analysis and Machine Intelligence, vol. Pami-5, n° 6, pag. 573-583, IEEE Computer Society Press 1983.
- [D'Astous 84]** D'Astous, F. y Jernigan M. "Texture discrimination based on detailed measures of the power spectrum". 7th International Conference on Pattern Recognition Proceedings, pag. 83-86, Montreal 1984.
- [Fong 84]** Fong, A., Ni, L. y Wong, Y. "Fast Discrimination Between Homogeneous and Texture Regions". 7th International Conference on Pattern Recognition Proceedings, pag. 361-363, Montreal 1984.

- [Gibson 50] Gibson, J.J. "The Perception of the Visual World". Houghton Mifflin. Boston, 1950.
- [Gibson 79] Gibson, J.J. "The Ecological Approach to Visual Perception". Houghton Mifflin. Boston, 1979.
- [Haralick 73] Haralick, R., Shanmugam, K. y Dinstein, I. "Textures, features for image classification". Transaction on systems, Man and Cybernetic, vol. 3, pag. 610-621, IEEE Computer Society Press 1973.
- [Haralick 83] Haralick, R. "Ridges and Valleys on Digital Images". Computer Vision, Graphics and Images Processing, vol. 22, pag. 28-38, Academic Press Inc., 1983.
- [Helmholtz 25] Helmholtz H. von. "Treatise on Physiological Optics". Dover. New York 1925.
- [Horn 75] Horn, B.K.P. "Obtaining shape from shading information". In The Psychology of Computer Vision. P.H. Wilston, pag. 115-155. McGraw-Hill. New York 1975.
- [Julesz 75] Julesz, B. "Experiments in the visual perception of texture". Scientific American , vol. 232 , n° 4 pag 2-11, 1975.
- [Land 71] Land, E.H.. "Lightness and retinex theory". Journal Optical Society American, vol. 61, pag. 1-11, 1971.
- [Laws 80] Laws, K. "Textured image segmentation". USC IPT Report 940, Los Angeles, University of Southern California, 1980.
- [Lowitz 83] Lowitz, G. "Images, principes, traitements et applications". Session extraordinaire de L'Ecole Internationale d'Informatique afcet. Inset, Universite d'Abidjan, Cote d'ivoire 1983.
- [Lowitz 84] Lowitz, G. "Mapping the local information context of a spatial image". C.E.S.T.A.- Premier Colloque Image, Biarritz 1984.
- [Marr 76] Marr, D. "Artificial Intelligence- A personal view". Artificial Intelligence, vol. 9, pag. 37-48, 1976.
- [Marr 77] Marr, D., y Poggio, T. "From understanding computation to understanding neural circuitry". Neuroscience Research Progress Bulletin, vol. 15, pag. 470-488, 1977.

- [Marr 82] Marr, D. "Vision: A Computational Investigation into the Human Representation and Processing of Visual Information". Freeman, 1982.
- [Mira 84] Mira, J., Moreno, R. y Delgado, A. "Towards a Cybernetic Methodology". 6th International Congress of Cybernetic and Systems AF CET proceeding, pag. 819-824, Paris 1984.
- [Moreno 78] Moreno, R., Rubio, E. "A generalized model for non-linear retinal processing". Current topics in Cybernetic and Systems, Springer-Verlag 1978.
- [Moreno 91] Moreno, R. "Natural and Artificial Nets". AIWAN, Opening Lecture. Granada 1991.
- [Muñoz 87] Muñoz, J. "Jerarquización de estructuras de nivel bajo y medio para reconocimiento visual. Aplicaciones en texturas y formas". Tesis Doctoral, 1987.
- [Muñoz 94] Muñoz, J., García, C., Alayón, F. y Candela, S. "System concepts for visual texture changes detection strategy". Lectures Notes in Computer Science, vol. 763, pag 357-365, Springer-Verlag 1994.
- [Neubauer 92] Neubauer, C. "Segmentation of Defects in Textile Fabric". International Conference on Pattern Recognition proceeding, pag. 688-691, IEEE Computer Society Press, 1992.
- [Pichler 88] Pichler, F. "Computer Aided Systems Theory: Framework for interactive Method Bank". Cybernetics and System, vol. 88, pag 737-786, Kluwer Academic Publishers Dordrech, The Netherlands, 1988.
- [Roning 86] Roning, J. y Hall, E. "Shape, Form y Texture Recognition for Automotive Brake Pad Inspection". Automated Inspection and Measurement, vol. 730, pag. 82-90, SPIE 1986.
- [Rao 91] Rao, A. y Schunck, B. "Computing oriented texture fields". CVGIP: Graphical Models Image Process, vol. 53, pag. 157-185, Academic Press 1991.
- [Rao 93] Rao, A. y Lohse, G. "Identifying High Level Features of Textures Perception". GVGIP: Graphical Models and Image Process, vol. 55, nº 3, pag. 218-233, Academic Press Inc. 1993.

- [Reed 93] Reed, T. y Hans du Buf, J. "A Review of Recent Texture Segmentation and Feature Extraction Techniques". *GVGIP: Image Understanding*, vol. 57, n° 3, pag. 359-372, Academic Press 1993.
- [Rovaris 92] Rovaris, E. "Imágenes, muestreo y computación distribuida de tipo computacional: hacia un enfoque unificado". Tesis Doctoral, 1992.
- [Siew 88] Siew, H. y Hodgson, R. "Texture Measures for Carpet Wear Assessment". *Transactions on Pattern Analysis and Machine Intelligence*, vol. 10, n° 1, IEEE Computer Society Press 1988.
- [Unser 82] Unser, M. y Coulon, F. "Detection of defects by textures monitoring in automatic visual inspection". *Proceeding of the 2nd. International Conference on Robot Vision and Sensory Controls*, pag. 27-38, Stuttgart 1982.
- [Wang 90] Wang, L. y He, D. "A New Statistical Approach for Texture Analysis". *Photogrammetric Engineering and Remote Sensing*, vol. 56, pag. 61-66, American Society for Photogrammetry and Remote Sensing 1990.
- [Weszka 76] Weszka, C. Dyer y Rosenfeld, A. "A comparative study of texture measure for Terrain Classification". *Transaction on System, Man and Cybernetics*, vol. 4, IEEE Computer Society Press 1976.
- [Wildes 90] Wildes, R. "Computational Vision with Reference to Binocular Stereo Vision". *Science of Vision*, pag 332-364. Springer-Verlag, 1990.
- [Wood 81] Woods, R., Gonzalez R. "Real-time adaptive contrast enhancement". *Transactions on Pattern Analysis and Machine Intelligence*, vol. Pami-3, n° 6, pag. 655-661, IEEE Computer Society Press 1981.
- [You 93] You, J. y Cohen, A. "Classification and segmentation of rotated and scaled textured images using texture 'tuned' masks". *Pattern Recognition*, vol. 26, n° 2, pag. 245-258. Pattern Recognition Society 1993.
- [Zucker 81] Zucker, S., Terzopoulos, D. "Finding structure in cooccurrence matrices for texture analysis". *Image Modeling*, Academic Press Inc. 1981.