

Universidade de Vigo

Marcos Xosé Álvarez Cid  
*Modelo unificado para la caracterización de texturas en imágenes digitales mediante histogramas de patrones equivalentes*

Marcos Xosé Álvarez Cid

*Modelo unificado para la caracterización de texturas en imágenes digitales mediante histogramas de patrones equivalentes*

Dep. Enxeñaría dos Recursos Naturais e Medio Ambiente

Universidade de Vigo

Universidade de Vigo

Escola Técnica  
Superior de  
Enxeñaría de Minas

MODELO UNIFICADO PARA LA  
CARACTERIZACIÓN DE TEXTURAS EN  
IMÁGENES DIGITALES MEDIANTE  
HISTOGRAMAS DE PATRONES  
EQUIVALENTES

*Autor:*  
Marcos Xosé Álvarez Cid

*Directores:*  
Antonio Fernández Álvarez  
Julia Armesto González

5 de julio de 2011

---

Universida<sub>de</sub>Vigo







# Modelo Unificado para la Caracterización de Texturas en Imágenes Digitales mediante Histogramas de Patrones Equivalentes

Memoria que presenta **Marcos Xosé Álvarez Cid** para optar al  
título de **Doctor por la Universidade de Vigo**

Vigo, 5 de julio de 2011

Directores: **Antonio Fernández Álvarez**  
Universidade de Vigo  
Departamento de Deseño na Enxeñaría

**Julia Armesto González**  
Universidade de Vigo  
Departamento de Enxeñaría dos Recursos Naturais e Medio Ambiente

---

Universidade de Vigo

Este documento ha sido escrito por el autor en L<sup>A</sup>T<sub>E</sub>X 2<sub>ε</sub> con el editor TeXnicCenter 1.0 y compilado con MiKTeX 2.8.

El trabajo de investigación que se describe en esta memoria se ha realizado en el Laboratorio de Colorimetría, Escola de Enxeñaría Industrial, Universidade de Vigo.



**Reconocimiento - NoComercial - CompartirIgual (by-nc-sa):** No se permite un uso comercial de la obra original ni de las posibles obras derivadas, la distribución de las cuales se debe hacer con una licencia igual a la que regula la obra original.

aos que resisten, porque ao final sempre gañan





# Agradecimientos

Fue una tarde de finales de octubre de 2007 cuando, el que a la postre se convertiría en mi director de tesis, me hizo la pregunta total: “¿Has considerado en alguna ocasión la posibilidad de iniciar una carrera investigadora?” Tres años y medio después aquí me encuentro, haciendo balance de lo vivido durante un período no exento de penurias y contratiempos, pero también plagado de satisfacciones y buenos momentos. Se hace necesario, por lo tanto, hacer una mención a aquellos y aquellas que me han acompañado a lo largo de esta travesía.

En primer lugar, debo destacar especialmente a Antonio Fernández, el de la famosa pregunta, por su abnegada dedicación durante todo este tiempo. Con frecuencia se oyen duras críticas, más si cabe en estos tiempos, a la universidad pública española y a los que en ella trabajan. Se dice, por ejemplo, que ninguna institución universitaria del país se encuentra entre las 100 mejores del mundo. Por mi parte, tengo claro que los gurús que preconizan el colapso de nuestro sistema universitario, para muchos de los cuales pesa más en sus consideraciones la prima de riesgo de la deuda soberana que el número de titulados recibidos anualmente con los brazos abiertos en el extranjero –por algo será–, toman la parte por el todo y deberían darse una vuelta por el despacho de mi director de tesis. Trabajo, tesón, sacrificio, honestidad, pasión por la ciencia . . . , es lo que encontrarán.

A continuación quisiera dar las gracias igualmente a mi codirectora, Julia Armesto, por el ánimo brindado especialmente durante los últimos meses de este trabajo; a Pedro Arias, por su apoyo incondicional y su fe en mi labor; al resto de miembros del Lab-18 de Minas –los que están y los que han estado–, por haberme tratado como uno más, a pesar de la distancia y de que realmente resulta extraño pensar en un teleco, miembro de un grupo de investigación de Minas, trabajando en un laboratorio de Industriales.

Asimismo la ayuda y el cariño brindados por los profesores Elena González, Francesco Bianconi, durante sus estancias en Vigo, y Fernando J. Aguilar, que gustosamente nos ha facilitado la imagen de satélite utilizada en los experimentos, han sido destacables. Tampoco me puedo olvidar del apoyo prestado por Camilo Carrillo y Eloy Díaz.

A diario he compartido un rato cada mañana con Pablo Izquierdo y José Manuel Santos, del Laboratorio de Energía Solar de la Universidad de Vigo, en el que hemos intercambiado experiencias y nos hemos contado nuestras penas y nuestros éxitos. Esperemos que, sean cuales sean nuestros respectivos caminos a partir de ahora, se siga manteniendo el buen humor.

*Last, but not least*, espero que el lector me permita la licencia de incluir un apartado un poco más personal. Mis padres y mi hermano me han acompañado durante toda mi vida académica y profesional. Quisiera agradecerles especial-

mente su apoyo durante este último tramo, en el que he tenido que afrontar decisiones importantes y normalmente de difícil comprensión para el común de los mortales, como por ejemplo abandonar un trabajo en la empresa privada y volver a la universidad. Y para terminar, me reservo unas palabras para Eva, que es la que más claro ha visto eso de que me embarcara en esta ardua tarea y la que ha seguido más de cerca mis peripecias, sobre todo durante el último año, en el que ha decidido probar el *Vigo's way of life*. Han sido años de simultanear estudio y trabajo, de vivir casi permanente en la cuerda floja –algo de lo que, por cierto, no me creía capaz y a lo que casi me he acostumbrado–, de robarle tiempo al tiempo. Supongo que a partir de ahora el horizonte se despejará y podremos celebrarlo como se merece. Un beso y un abrazo por tu paciencia.

*This is the end, my only friend, the end.* Es indudable que aquí se cierra una etapa. Ya veremos lo que viene a continuación. Esta es en cierta medida la misma sensación de incertidumbre que me rodeaba cuando me metí en este embrollo. Hace unas pocas semanas Iñaki Gabilondo pronunció una cita que resume a la perfección el estado de ánimo en el que me encuentro llegado a este punto: “*Escépticos por supuesto, desanimados, también. Pero rendirse, nunca*”. Pues eso, apliquémonos el cuento.

Vigo, 25 de abril de 2011, día de San Marcos y 37º aniversario de la Revolución de los Claveles.

# Resumen

La textura es una de las propiedades que aporta más información al sistema humano de visión acerca de los objetos y superficies que percibimos. Por este motivo, el análisis de texturas, que se ocupa del desarrollo e implementación de técnicas *hardware* y *software* con el objetivo de solucionar una serie de problemas canónicos relacionados con el reconocimiento automático de objetos y superficies en imágenes digitales, ha alcanzado una gran popularidad dentro del ámbito de la visión por computador. La relevancia del análisis de texturas se manifiesta a través del amplio abanico de aplicaciones en las que se viene considerando desde hace cuatro décadas: teledetección, diagnóstico médico, robótica, monitorización de procesos, seguridad o control de calidad, por citar sólo algunas.

Desafortunadamente el concepto de textura es subjetivo e impreciso, lo que dificulta extraordinariamente su caracterización de manera analítica y universal y, por lo tanto, su definición. Podría decirse que somos capaces de reconocer la textura cuando la vemos, pero nos resulta difícil formalizarla en términos concretos. Además, hasta el momento no se ha podido alcanzar una completa comprensión de la naturaleza física de este fenómeno.

Así, la mayor parte del esfuerzo investigador invertido hasta el momento en relación con el análisis de texturas se ha centrado en aportar soluciones a problemas concretos, es decir, *ad hoc*, basadas frecuentemente en consideraciones de tipo empírico. El objetivo que persiguen estos trabajos es demostrar la superioridad de un nuevo descriptor de textura frente a otros ya existentes, aunque no suelen justificar los resultados obtenidos en función de consideraciones de tipo teórico. Esta filosofía ha motivado la aparición de numerosos descriptores de índole muy diversa, lo que explica en gran medida las dificultades que presenta su categorización.

Buscando solventar en la medida de lo posible esta situación, en esta tesis doctoral presentamos un marco teórico que nos ha permitido formalizar matemáticamente y unificar un amplio conjunto de descriptores de textura considerados hasta la fecha de manera inconexa, obviando que, en realidad, todos ellos se basan en el mismo principio de funcionamiento: el establecimiento de una relación de equivalencia entre patrones de textura en escala de grises para representar la textura mediante un histograma de dimensión reducida. El modelo unificado que proponemos es simple, compacto y flexible, por lo que está abierto a la incorporación de nuevos métodos que puedan aparecer en el futuro. Para demostrar su potencia y su capacidad de generalización, hemos desarrollado una nueva familia de descriptores de textura, a la que hemos denominado Gradientes Binarios de Contorno o *Binary Gradient Contours* (BGC). Los miembros de la familia BGC destacan por su simplicidad teórica, así como por su reducido coste computacional.

Tradicionalmente, la búsqueda del descriptor de textura óptimo en términos de poder de discriminación intrínseco se ha abordado por medio de estudios comparativos, en los que el factor de calidad que se suele analizar es la tasa de acierto. En nuestra opinión, los estudios de este tipo son parciales y carecen de suficiente rigor y representatividad, principalmente por tres motivos. En primer lugar, resulta inviable considerar simultáneamente todos los descriptores de textura propuestos hasta el momento. Además, en cada uno de estos trabajos se maneja un número limitado de colecciones de imágenes, diferentes en cada caso, por lo que la extrapolación de los resultados obtenidos es inviable. Por último, aparte de la tasa de acierto, existen otros factores que pueden resultar de interés para analizar la bondad de un determinado descriptor de textura, como son el tiempo de cómputo o su dimensión.

Por otra parte, hemos diseñado un experimento de clasificación de imágenes de textura estacionaria a partir de cuyos resultados hemos podido efectuar una amplia comparativa en la que se han incluido todos aquellos descriptores que encajan en el modelo unificado propuesto. Para validar el experimento se ha construido un banco de pruebas formado por 10 bases de datos que incluyen colecciones de imágenes digitales procedentes de diversas fuentes. Este es, por lo que sabemos, el mayor análisis comparativo que se ha completado dentro de esta línea de investigación, lo que supone que las conclusiones que se extraen de nuestro trabajo adquieren un carácter más general que las de otras publicaciones anteriores. Finalmente, para estudiar si las diferencias existentes entre las tasas de acierto de los diferentes descriptores son significativas, se ha realizado un análisis estadístico de hipótesis basado en el test de los rangos con signo de Wilcoxon. Asimismo hemos desarrollado un experimento de clasificación de objetos sobre una imagen de satélite de alta resolución con el fin de estudiar la viabilidad de introducir descriptores de textura en un problema presente en el ámbito de la teledetección, como es la detección automática de invernaderos, confirmando la validez de las conclusiones extraídas a partir del primer experimento y, por lo tanto, la utilidad de este enfoque en una aplicación de estas características.

**Palabras clave:** Visión por computador, análisis de texturas, clasificación de imágenes, patrones equivalentes, BGC, LBP.

# Abstract

Texture is one of the properties that provides more information to the human vision system about the objects and surfaces that we perceive. This is the reason why texture analysis, that involves the development and implementation of hardware and software techniques aiming to solve several canonical problems related to the automatic recognition of objects and surfaces in digital images, has achieved a remarkable popularity within the computer vision subject. The wide range of applications that have benefited from the progress in texture analysis during the last four decades, like remote sensing, medical diagnosis, robotics, process monitoring, security or quality control, to cite some, show its significance.

Unfortunately, the analytical and universal characterisation of texture, and therefore its definition, are extremely complicated, as such concept is subjective and imprecise. It should be pointed out that we are able to recognize texture when we see it, but it is very difficult to define. Besides, a complete understanding of the physical nature of this phenomenon has not been achieved yet.

As a consequence, most of the research effort regarding texture analysis has been focused on obtaining solutions to specific problems, which are frequently based on empirical considerations. These works aim to show the superiority of a new texture descriptor over the existing ones, although it is unusual to justify the obtained results in a theoretical way. This philosophy has boosted the introduction of a wide variety of descriptors, which explains to a large extent the difficulty of categorizing texture descriptors.

In this doctoral thesis we present a theoretical framework that has allowed us to unify and mathematically formalise a wide group of texture descriptors that have been considered independently until now, though they share the same underlying principle: texture is represented through a histogram whose dimension is reduced by defining an equivalence relation between grayscale texture patterns.

The unified model we propose is simple, yet compact and flexible, so that it allows the inclusion of new methods that might appear in the future. We have developed a new family of texture descriptors, namely the Binary Gradient Contours (BGC), to show the power and generalisation ability of our framework. The BGC family members feature a remarkable theoretical simplicity, as well as a reduced computational cost.

Traditionally, the problem of searching an optimal texture descriptor in terms of intrinsic discriminative power has been addressed through comparative studies, where success rate is usually the only quality index considered. From our point of view, such studies are biased and lack enough soundness, primarily for three reasons. First of all, it is unfeasible to consider at the same

time all the texture descriptors proposed so far. In addition, each of these works handles a different and limited number of image collections, so that the obtained results are strongly dependent on the data used in the experiments, and hence, the conclusions cannot be straightforwardly extrapolated to different datasets. Finally, other aspects, apart from the success rate, may be of interest to analyze the goodness of a particular texture descriptor, such as its computation time or dimension.

In this thesis, we have designed an stationary texture image classification experiment that has allowed us to perform a comprehensive comparison study between all those descriptors that fit the unified model we have proposed. In order to validate the experiment, a benchmark consisting of 10 image databases from various sources has been gathered. This is, to the best of our knowledge, the largest comparative analysis that has been carried out within this research topic, so that the conclusions drawn from our work are more general than those from previous publications. Finally, a statistical analysis based on the Wilcoxon signed rank test was performed to determine whether the descriptors considered in our work have shown significant differences among them or not. We have also developed an object classification experiment on a high resolution satellite image to study the feasibility of introducing texture descriptors in a remote sensing problem, such as the automatic detection of greenhouses is, confirming the validity of the conclusions drawn from the first experiment and, therefore, the usefulness of this approach in such an application.

**Keywords:** Computer vision, texture analysis, image classification, equivalent patterns, BGC, LBP.

# Índice general

<b>Agradecimientos</b>	<b>I</b>
<b>Resumen</b>	<b>III</b>
<b>Abstract</b>	<b>V</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Noción de textura . . . . .	1
1.2. Percepción de la textura . . . . .	4
1.3. Análisis de texturas . . . . .	7
1.3.1. Problemas canónicos . . . . .	8
1.3.2. Aplicaciones . . . . .	11
1.4. Descriptores de textura . . . . .	13
1.4.1. Taxonomía . . . . .	14
1.4.2. Estudios comparativos . . . . .	15
1.5. Interés de la tesis . . . . .	17
<b>2. Modelo unificado</b>	<b>19</b>
2.1. Histograma de patrones . . . . .	19
2.2. Formalización del modelo . . . . .	21
2.3. Tipos de correspondencias . . . . .	24
2.3.1. Marginalización . . . . .	24
2.3.2. Umbralización . . . . .	27
2.3.3. Ordenación . . . . .	33
2.4. Extensiones del modelo . . . . .	34
2.4.1. Preprocesamiento . . . . .	35
2.4.2. Extracción de características del histograma . . . . .	36
2.4.3. Composición de correspondencias . . . . .	36
2.4.4. Multiescala . . . . .	37
2.4.5. Diccionario de patrones . . . . .	38
2.4.6. Lógica borrosa . . . . .	39
<b>3. Gradientes Binarios de Contorno</b>	<b>41</b>
3.1. Nuevos descriptores de textura . . . . .	41
3.2. Eficiencia teórica . . . . .	44
3.3. Análisis comparativo . . . . .	46
3.3.1. BGC frente a LBP . . . . .	46
3.3.2. Versiones de la BGC . . . . .	47



<b>4. Experimentos</b>	<b>51</b>
4.1. Datos utilizados . . . . .	52
4.1.1. Texturas genéricas . . . . .	52
4.1.2. Granitos . . . . .	56
4.1.3. Imágenes de satélite . . . . .	57
4.2. Metodología experimental . . . . .	58
4.3. Resultados obtenidos . . . . .	60
4.3.1. Clasificación de imágenes . . . . .	61
4.3.2. Clasificación de objetos . . . . .	66
<b>5. Conclusiones</b>	<b>69</b>
<b>Apéndices</b>	<b>73</b>
<b>A. Bases de datos y resultados</b>	<b>75</b>
A.1. Brodatz . . . . .	76
A.2. Jerry Wu . . . . .	78
A.3. KTH-TIPS . . . . .	80
A.4. KTH-TIPS2b . . . . .	82
A.5. Mondial Marmi . . . . .	84
A.6. Outex TC_00000 . . . . .	86
A.7. Outex TC_00001 . . . . .	88
A.8. Outex TC_00013 . . . . .	90
A.9. UIUCtex . . . . .	92
A.10. VisTex . . . . .	94
<b>B. Implementación en Matlab</b>	<b>97</b>
<b>Publicaciones</b>	<b>111</b>
<b>Bibliografía</b>	<b>113</b>
<b>Acrónimos</b>	<b>133</b>
<b>Índice alfabético</b>	<b>137</b>

# Índice de figuras

1.1. Distinción entre textura (a) y conjunto de objetos (b) en un pavimento. . . . .	2
1.2. Influencia de la escala sobre la textura: macrotextura (a) y microtextura (b) de una pared de bloques de hormigón. . . . .	3
1.3. Características de la textura visualmente relevantes (I). . . . .	5
1.4. Características de la textura visualmente relevantes (II). . . . .	6
1.5. Composiciones de textura en las que se manifiesta el proceso de discriminación preatentiva frente a la discriminación consciente. . . . .	7
1.6. Segmentación de imágenes aplicada a la detección de carreteras en un sistema de asistencia a la conducción de vehículos. . . . .	9
1.7. Síntesis de texturas. . . . .	10
1.8. Interfaz gráfica de la herramienta de búsqueda de imágenes basada en contenido <i>img(Anaktisi)</i> . . . . .	10
1.9. Extracción de la forma a partir de la textura. . . . .	11
1.10. Ejemplos de aplicación del análisis de texturas. . . . .	12
2.1. Representación esquemática de la caracterización de textura mediante histogramas de patrones equivalentes. . . . .	21
3.1. (a) Disposición espacial de un patrón $3 \times 3$ en escala de grises. Representación esquemática de las umbralizaciones correspondientes a los siguientes modelos: (b) BGC de bucle simple, (c) BGC de bucle doble, (d) BGC de bucle triple y (e) LBP. . . . .	42
3.2. Probabilidades <i>a priori</i> $P_f(k)$ de las clases de equivalencia que establecen las siguientes correspondencias: (a) $BGC_{1 \times 3}$ y $BGC_{3 \times 3}$ , (b) $BGC_{2 \times 3}$ y (c) $LBP_{3 \times 3}$ . Los histogramas se calcularon para $G = 12$ . . . . .	45
3.3. Relación entre la eficiencia teórica y el número de niveles de gris en los modelos BGC y LBP. . . . .	46
4.1. Región considerada en la imagen del satélite QuickBird. . . . .	58
4.2. Detalle de la región considerada y polígonos empleados para el <i>ground truth</i> . La clase <i>greenhouse</i> se representa en verde y la <i>nogreenhouse</i> en rojo. . . . .	59
4.3. Resumen de los resultados del experimento de clasificación de imágenes de textura estacionaria: (a) dimensión de los descriptores, (b) tasa de acierto promediada y (c) tiempo de cómputo relativo promediado. . . . .	62

---

4.4. Selección de los mejores descriptores ordenados de mayor a menor número de victorias en la prueba de Wilcoxon. . . . .	65
4.5. Distribución del tamaño de los polígonos empleados como <i>ground truth</i> y dimensión de los histogramas. . . . .	68
A.1. Texturas de la base de datos de Brodatz USC-SIPI. . . . .	76
A.2. Texturas de la base de datos de Jerry Wu. . . . .	78
A.3. Texturas de la base de datos KTH-TIPS. . . . .	80
A.4. Texturas de la base de datos KTH-TIPS2b. . . . .	82
A.5. Texturas de la base de datos de Mondial Marmi. . . . .	84
A.6. Texturas de la base de datos Outex_TC.00000. . . . .	86
A.7. Texturas de la base de datos Outex_TC.00001. . . . .	88
A.8. Texturas de la base de datos Outex_TC.00013. . . . .	90
A.9. Texturas de la base de datos UIUCTex. . . . .	92
A.10. Texturas de la base de datos VisTex. . . . .	94

# Índice de tablas

2.1. Correspondencias basadas en marginalización. . . . .	26
2.2. Correspondencias basadas en umbralización. . . . .	28
2.3. Correspondencias basadas en ordenación. . . . .	34
3.1. Resumen de características de los modelos de textura considerados: dimensión del espacio de características ( $K$ ), máxima entropía alcanzable expresada en bits ( $\log_2 K$ ), eficiencia teórica ( $e_f$ ) calculada para $G = 12$ niveles de cuantización, separación entre píxeles ( $\ \delta\mathbf{r}\ $ ), y orientaciones del gradiente ( $\theta$ ). . . . .	48
4.1. Resumen de características de las bases de datos empleadas en los experimentos de clasificación de imágenes de textura estacionaria. . . . .	56
4.2. Resultados del test de Wilcoxon. . . . .	64
4.3. Porcentaje de polígonos correctamente clasificados. . . . .	67
A.1. Resultados: Brodatz y marginalización. . . . .	76
A.2. Resultados: Brodatz y ordenación. . . . .	76
A.3. Resultados: Brodatz y umbralización. . . . .	77
A.4. Resultados: Jerry Wu y marginalización. . . . .	78
A.5. Resultados: Jerry Wu y ordenación. . . . .	78
A.6. Resultados: Jerry Wu y umbralización. . . . .	79
A.7. Resultados: KTH-TIPS y marginalización. . . . .	80
A.8. Resultados: KTH-TIPS y ordenación. . . . .	80
A.9. Resultados: KTH-TIPS y umbralización. . . . .	81
A.10. Resultados: KTH-TIPS2b y marginalización. . . . .	82
A.11. Resultados: KTH-TIPS2b y ordenación. . . . .	82
A.12. Resultados: KTH-TIPS2b y umbralización. . . . .	83
A.13. Resultados: Mondial Marmi y marginalización. . . . .	84
A.14. Resultados: Mondial Marmi y ordenación. . . . .	84
A.15. Resultados: Mondial Marmi y umbralización. . . . .	85
A.16. Resultados: Outex TC_00000 y marginalización. . . . .	86
A.17. Resultados: Outex TC_00000 y ordenación. . . . .	86
A.18. Resultados: Outex TC_00000 y umbralización. . . . .	87
A.19. Resultados: Outex TC_00001 y marginalización. . . . .	88
A.20. Resultados: Outex TC_00001 y ordenación. . . . .	88
A.21. Resultados: Outex TC_00001 y umbralización. . . . .	89
A.22. Resultados: Outex TC_00013 y marginalización. . . . .	90
A.23. Resultados: Outex TC_00013 y ordenación. . . . .	90

A.24.Resultados: Outex TC_00013 y umbralización. . . . .	91
A.25.Resultados: UIUCTex y marginalización. . . . .	92
A.26.Resultados: UIUCTex y ordenación. . . . .	92
A.27.Resultados: UIUCTex y umbralización. . . . .	93
A.28.Resultados: Vistex y marginalización. . . . .	94
A.29.Resultados: Vistex y ordenación. . . . .	94
A.30.Resultados: Vistex y umbralización. . . . .	95

# Capítulo 1

## Introducción

En el mundo real los objetos están limitados por superficies que no son perfectamente lisas ni uniformes puesto que siempre presentan una cierta rugosidad. Esta heterogeneidad espacial, que habitualmente relacionamos con el concepto de textura, se percibe visualmente como una serie de variaciones significativas en los niveles de intensidad a escalas mucho menores que la de la escena. La textura es –junto con el color, el contraste, el brillo, la forma o la distribución espacial de los objetos– una de las propiedades que permiten la caracterización de una imagen. De hecho, el sistema humano de visión es capaz de procesar la información de textura contenida en una escena para llegar a comprenderla, localizar regiones de interés o identificar el material del que está hecho un objeto.

La relevancia de esta propiedad visual, la popularización de los dispositivos de captura de imagen y el incremento y abaratamiento de la potencia de cálculo disponible han provocado un creciente interés por el análisis de texturas y el desarrollo de sus potenciales aplicaciones. Desafortunadamente aún no se ha alcanzado una completa comprensión de la naturaleza física de este fenómeno, por lo que no existe ninguna formalización que permita extraer modelos capaces de caracterizar la textura presente en una imagen de manera analítica y universal.

En este capítulo introduciremos el concepto de textura desde dos perspectivas a simple vista diferentes pero íntimamente relacionadas entre sí. Por una parte analizaremos todos aquellos factores que determinan su definición y por otra consideraremos los aspectos psicofísicos que influyen en la forma en que la percibimos. A continuación ofreceremos una panorámica general de las principales aplicaciones de estos modelos en tareas de procesamiento digital de imágenes, y finalmente describiremos el objetivo de la presente tesis y justifiaremos su interés.

### 1.1. Noción de textura

En castellano, el término «textura» cuenta con numerosas acepciones. De acuerdo con su etimología latina, podemos hablar de la textura de un tejido al tratar de describir la disposición de los hilos o hebras que lo conforman [200]. No obstante, la evolución lingüística sufrida por el significado original ha provocado que hoy en día sea posible emplear la misma palabra para referirnos además

a conceptos tan distintos como la textura de la música [208], la textura de un vino [90] o la textura de una pintura [63], por poner algunos ejemplos. Podemos reconocer fácilmente que la textura es una sensación, una propiedad de las cosas que percibimos a través de nuestros órganos sensoriales y que las diferencias semánticas que acabamos de exponer se deben básicamente a que en cada contexto predomina la intervención de un sentido sobre los demás.

El concepto de textura, entendido como propiedad visual de la superficie de un objeto, es subjetivo e impreciso. Podría decirse que somos capaces de reconocer la textura cuando la vemos, pero nos resulta difícil formalizarla en términos concretos, como lo demuestra la amplia variedad de definiciones que se han propuesto [51], muchas de las cuales hacen referencia a una aplicación particular y están condicionadas por el punto de vista o la formación inicial del autor. A pesar de la existencia de múltiples definiciones cualitativas, ninguna de ellas goza de una aceptación generalizada. Ello se debe a que todavía no se ha logrado extraer un modelo matemático del que se derive una definición cuantitativa universal.

Un aspecto en el que sin embargo coinciden todas las definiciones de textura es en destacar su carácter regional. Esto significa que la textura debe entenderse como una propiedad asociada a un área y no a un punto. Así pues, a diferencia de otros descriptores de imagen como el color, que es un atributo intrínseco de cada píxel por separado, para poder hablar de textura es preciso tener en cuenta un conjunto de píxeles.

Otra conclusión que se extrae de la mayoría de las definiciones es la fuerte influencia que ejerce la escala sobre la interpretación de la textura. Tanto es así que un cambio de escala puede incluso llegar a provocar que se pierda la sensación de textura, como ilustramos en la Figura 1.1. En efecto, es inmediato comprobar que en determinadas ocasiones, si se amplía la escala de una imagen de textura –Figura 1.1(a)–, el efecto que se consigue es que la imagen aparente estar formada por un conjunto de objetos aislados en lugar de constituir un todo homogéneo –Figura 1.1(b)–, si bien es cierto que con frecuencia no está claro dónde se sitúa la frontera entre ambos «estados».



Figura 1.1: Distinción entre textura (a) y conjunto de objetos (b) en un pavimento.

En otras situaciones, un cambio de escala no acarrea la pérdida de la sensación de textura, pero sí una variación significativa de la forma en que la percibimos. En la Figura 1.2 se muestran dos texturas de apariencia muy dis-

tinta, aunque son dos fotografías de una misma pared de bloques de hormigón tomadas ajustando el *zoom* en dos posiciones diferentes. Mientras que es inmediato identificar la Figura 1.2(a) como una pared de bloques, la Figura 1.2(b) se podría confundir fácilmente con una textura de cuero sintético o poliestireno expandido, por poner sólo dos ejemplos.



Figura 1.2: Influencia de la escala sobre la textura: macrotextura (a) y microtextura (b) de una pared de bloques de hormigón.

Como consecuencia de la fuerte influencia de la escala sobre la textura se suele abordar su análisis desde dos perspectivas diferentes, que son el origen de los conceptos de macrotextura y microtextura [148, 266]. Desde el punto de vista de la macrotextura, la textura es un fenómeno eminentemente macroscópico, cuya estructura viene dada por la repetición de ciertos elementos –usualmente denominados primitivas o *texels*<sup>1</sup>–, de acuerdo a una determinada regla de colocación [92, 205]. Así, las imágenes formadas por un número elevado de pequeños objetos se percibirían como textura, siempre y cuando ninguno de esos elementos suscite una especial atención y el conjunto de todos ellos cause una impresión global uniforme [61]. Por su parte, desde el punto de vista de la microtextura, la textura es un fenómeno que se produce a escalas menores que la escala de interés, por lo que para analizarla será necesario estudiar lo que ocurre en la vecindad de cada uno de los píxeles que conforman una imagen [75, 199]. Estos dos niveles del modelo jerárquico de textura no son completamente independientes porque, en realidad, la macrotextura se puede considerar como una agregación homogénea de microtextura. Como criterio general, diremos que una imagen contiene textura si está compuesta por un número incontable de *texels*. En la presente tesis contemplamos el análisis de texturas desde la perspectiva de la microtextura.

Una de las cuestiones más polémicas acerca de la noción de textura es su relación con el color. Las primeras definiciones relacionaban la textura exclusivamente con variaciones espaciales de intensidad en una imagen en escala de grises, descartando por completo el color. Sin embargo, a medida que el análisis de texturas fue alcanzando un cierto grado de madurez, esta situación evolucionó y aparecieron nuevas definiciones en las que se tenía en cuenta la información

<sup>1</sup>En computación gráfica, un *texel* –*texture element*– representa la unidad mínima en la que se descomponen las texturas. El término *texel* es análogo a *pixel* –*picture element*–, que se corresponde con la superficie homogénea más pequeña de las que componen una imagen y está definida por su brillo y color.



cromática [60, 213]. En la actualidad hay un elevado grado de consenso sobre la conveniencia de considerar el color en el análisis de texturas, aunque existe controversia sobre la forma en que deben combinarse ambas propiedades. Esta diferencia de criterios ha traído como consecuencia la aparición de dos tendencias claramente diferenciadas [160]. Por una parte están los métodos que consideran que textura y color deben estudiarse simultáneamente [110, 185, 206] y por otra, los que procesan estas propiedades por separado [65, 232]. Los autores que abogan por la segunda opción se basan en estudios psicológicos que demuestran que el sistema visual humano funciona de manera análoga [169, 196]. En cualquier caso, los estudios realizados hasta la fecha revelan que los resultados que se obtienen al incorporar el color dependen fuertemente de las condiciones de iluminación. Además, en muchos casos la mejora que proporciona la incorporación del color no compensa el incremento del coste computacional asociado. Es por ello que hemos decidido restringir el ámbito de esta tesis al enfoque clásico, es decir, al estudio de técnicas de extracción de características a partir de imágenes en escala de grises, descartando por lo tanto la información de color.

En definitiva, una parte importante del problema conocido como «análisis de texturas» sería definir exactamente qué es la textura, aunque como acabamos de exponer, no es tarea fácil. Para subsanar la carencia de una definición precisa, es habitual describir la textura de forma intuitiva a través de una serie de términos de uso coloquial que hacen referencia a determinadas cualidades o atributos. Como veremos a lo largo de la siguiente sección, este planteamiento nos permitirá distinguir dos o más texturas por comparación, y así podremos afirmar que una textura es más o menos «gruesa», «fina», «suave», «compacta», «granulada», etc.

## 1.2. Percepción de la textura

La visión por computador es la ciencia que desarrolla la teoría y la tecnología que permiten extraer o deducir automáticamente información acerca de las estructuras y propiedades del mundo que nos rodea a partir de una o varias imágenes [172]. Por su parte, la visión biológica estudia y modela los procesos fisiológicos que posibilitan la percepción visual en los humanos y en otros animales. A pesar de que la visión por computador tiene un fundamento matemático, está íntimamente ligada al estudio de la visión biológica, ya que su objetivo primordial es implementar aquellos procesos mediante *software* y *hardware*. En el desarrollo de ambas disciplinas con frecuencia se ha producido una realimentación mutua que ha resultado muy provechosa.

El trabajo desarrollado por los pioneros en el ámbito de la percepción visual de la textura ha demostrado que ésta desempeña un papel primordial en las tareas de discriminación visual y que esas tareas dependen principalmente de una serie de propiedades psicológicas del sistema visual [116]. En numerosas ocasiones los expertos en el análisis de texturas han soslayado la relación existente entre visión por computador y visión biológica, siguiendo un planteamiento totalmente heurístico en el que lo único que se busca es una caracterización de la textura que proporcione resultados satisfactorios a la hora de solucionar un problema concreto, aunque esa descripción matemática no se corresponda con ningún modelo psicofísico. Esta forma de abordar el problema de la textura obvia la definición subjetiva a la que estamos habituados en la vida cotidiana y

con la que finalizábamos la Sección 1.1.

Un enfoque más intuitivo y ajustado al fenómeno físico de la textura consiste en traducir cada uno de los adjetivos que empleamos para describir la textura en el lenguaje natural en alguna propiedad que derive de las interacciones espaciales que existen entre píxeles vecinos en una imagen, estableciendo características analíticas de la textura que sean visualmente relevantes, es decir, que establezcan una correspondencia con la percepción visual humana. Tamura, Mori y Yamawaki propusieron seis características: el grosor –previamente estudiado por Rosenfeld y otros [203, 93]–, el contraste, la direccionalidad, la similitud lineal, la regularidad y la dureza [231]. En las Figuras 1.3 y 1.4 ilustramos estas seis características contraponiéndolas con sus «antónimos». El grosor está relacionado con la escala y la repetición de la textura, el contraste captura su rango dinámico y la direccionalidad estima la orientación en una región de la imagen. Estas fueron las tres medidas que alcanzaron la máxima correlación con los resultados obtenidos en los tests psicológicos que se efectuaron sobre sujetos humanos. Los experimentos consistían en que cada sujeto ordenara una serie de texturas del álbum de Brodatz [41] con respecto a su impresión acerca de estos atributos subjetivos. Amadasun y King aportaron por su parte definiciones conceptuales para cinco propiedades: el grosor, el contraste, la saturación, la complejidad y la fortaleza de la textura [12]. Ambos trabajos derivan de las conclusiones a las que habían llegado los psicólogos de la escuela de la Gestalt a principios del siglo XX [128, 129], según los cuales las líneas o las regiones de brillo uniforme formadas por puntos próximos entre sí, es decir, caracterizadas por los conceptos de proximidad y uniformidad [116], participarían de manera decisiva en la discriminación visual.




Figura 1.3: Características de la textura visualmente relevantes (I).

Las aportaciones relacionadas con la fase preatentiva de la percepción han sido también muy importantes para conocer cómo se forma la ilusión de la textura en nuestro cerebro. La Figura 1.5 ilustra gráficamente este fenómeno, que podemos enunciar mediante la siguiente pregunta: ¿por qué unas veces se dis-

tinguen inmediatamente dos campos visuales diferentes y en otras ocasiones es necesario un proceso consciente más complejo de reconocimiento y comparación? En la mitad izquierda de la Figura 1.5(a) es posible distinguir a simple vista una banda vertical del resto de la imagen. Análogamente, en la Figura 1.5(b), a pesar de que la zona central de la imagen simplemente ha sufrido un cambio de orientación con respecto al fondo, es inmediato percibir un cambio en su textura. Sin embargo, la parte derecha de la Figura 1.5(a) se capta inicialmente como un conjunto homogéneo, aunque una visualización en detalle revela que efectivamente existen matices. Este sencillo ejemplo pone de manifiesto la existencia de una discriminación «sin esfuerzo» o preatentiva. Los trabajos de Julesz fueron fundamentales en esta área [116, 117, 119]. Una de sus contribuciones principales fue la «conjetura de Julesz», según la cual los humanos no seríamos capaces de discriminar dos texturas cuyos estadísticos de segundo orden fueran idénticos. Posteriormente, tanto él como otros autores aportaron numerosos contraejemplos que la refutaban [43, 44, 64, 73, 118, 120]. En cualquier caso, es un concepto que no se ha desechado por completo y se sigue recogiendo en la literatura, pues resulta útil para comprender los complejos mecanismos psicofísicos que rigen nuestra percepción de la textura.



Figura 1.4: Características de la textura visualmente relevantes (II).

Otra de las contribuciones derivadas del trabajo desarrollado por Julesz fue su teoría de los textones [121, 122, 123]. Los textones son componentes visuales elementales (rectángulos, elipses, segmentos, terminaciones de líneas, cruces, esquinas, etc.) cuya presencia es detectada por la visión preatentiva y utilizada para discriminar la textura. El sistema preatentivo ignora la forma exacta de estos componentes, pero es sensible a su longitud media, ancho y orientación. La teoría de los textones es el antecedente de numerosos descriptores estructurales de la textura, los cuales se basan en la extracción de primitivas como características locales de la textura. Por su parte, Marr, coetáneo de Julesz, llegó a conclusiones similares por un camino diferente con su «esbozo primitivo en bruto» (*raw primal sketch*) [167]. Esta representación descompone una imagen en




Figura 1.5: Composiciones de textura en las que se manifiesta el proceso de discriminación preatentiva frente a la discriminación consciente.

primitivas de cuatro tipos: bordes, barras, objetos amorfos y terminaciones.

Algunos fenómenos que no son coherentes con la teoría de los textones se pueden explicar partiendo de la hipótesis de que el sistema humano de visión actúa sobre la imagen captada en la retina efectuando un análisis local de la frecuencia espacial [59, 135], que se podría modelar matemáticamente mediante bancos de filtros [22, 24, 45, 52, 71, 230, 240]. Esta idea se basa en el modo de funcionamiento de mecanismos neurofisiológicos de respuesta lineal, como las neuronas que responden ante la aparición de manchas, líneas o bordes, que explican una serie de fenómenos de la visión espacial temprana [164]. Los filtros de Gabor son un claro ejemplo, ya que se ha demostrado que las características de ciertas células del córtex visual de algunos mamíferos se pueden modelar mediante una representación de este tipo [166].

En definitiva, se han desarrollado numerosas teorías en los campos de la neurociencia y de la psicofísica que permiten comprender el funcionamiento de la percepción humana de la textura y que han servido de punto de partida para el desarrollo de la visión por computador y del análisis de texturas. Algunos ejemplos destacados son la conjetura de Julesz, la teoría de los textones o el modelo frecuencial de las células corticales, que constituyen el fundamento de las técnicas estadísticas, estructurales y basadas en bancos de filtros respectivamente.

### 1.3. Análisis de texturas

Los sistemas de visión por computador manejan un conjunto de técnicas que se encuadran dentro del área de conocimiento denominada «análisis de imágenes» con el objetivo de extraer información relevante de las mismas. El análisis de texturas, que constituye una subdisciplina dentro del análisis de imágenes, se refiere a la caracterización del contenido de textura de una imagen.

En las últimas décadas el análisis de texturas ha experimentado un espectacular grado de desarrollo como consecuencia del abaratamiento y la popularización que han sufrido los dispositivos de adquisición de imágenes y del aprovechamiento de la creciente capacidad de cómputo disponible, lo que permite la utilización de potentes herramientas –tanto de *hardware* como de *software*– que facilitan las tareas de procesamiento digital de imágenes.

Las aplicaciones del análisis de texturas son variadas: teledetección, diagnóstico médico, robótica, monitorización de procesos, seguridad o control de calidad, por citar sólo algunas. La tendencia dominante en la actualidad consiste en el desarrollo de soluciones específicas para cada aplicación concreta, por lo que estos sistemas suelen utilizar información del dominio en el diseño de los algoritmos, ya que las soluciones generalistas no han ofrecido los resultados esperados.

Los factores que influyen en la efectividad de una determinada técnica de análisis de imágenes de textura son fundamentalmente tres: la aplicación en la que se enmarca, la naturaleza de las imágenes involucradas y el modelo empleado para describir la textura, siendo este último el más relevante. Por supuesto existen otros factores, como por ejemplo el criterio de similitud o la regla de decisión, pero en general su incidencia sobre las prestaciones globales es menor.

En esta sección describiremos brevemente los problemas fundamentales a los que el análisis de texturas se suele enfrentar –frecuentemente referidos en la bibliografía como problemas canónicos–, así como las principales aplicaciones en las que las técnicas asociadas a esta disciplina han resultado de utilidad hasta el momento.

### 1.3.1. Problemas canónicos

En el ámbito del análisis de imágenes digitales existe un conjunto de problemas particulares en los que la comprensión del fenómeno de la textura puede aportar soluciones satisfactorias. En ocasiones las fronteras entre ellos pueden ser difusas, aunque en otros casos las grandes diferencias en cuanto al planteamiento teórico y a los fines que se pretenden alcanzar hacen evidentes las distinciones. Los problemas canónicos clásicos, como la clasificación y la segmentación, están muy relacionados con la reproducción artificial del sistema humano de visión y se sustentan en una lógica deductiva, es decir, desde una descripción genérica de la textura caracterizamos una única imagen. Otros problemas, como la síntesis de texturas, tienen un enfoque inductivo: desde una pequeña muestra deseamos rellenar de textura una región de mayor tamaño que la original.

La extensión de la lista de problemas canónicos varía de unos autores a otros. Mientras que algunos hacen una categorización muy vasta, otros proponen una más detallada. A continuación enumeramos los problemas que, desde nuestro punto de vista, concentran a día de hoy el mayor esfuerzo investigador en esta área.

1. Clasificación. Es el problema de asignar una imagen con textura a una determinada clase o categoría [88]. El universo de posibles soluciones al problema es finito y se caracteriza *a priori* mediante un conjunto de imágenes de muestra, de las cuales se extraen medidas o vectores de características que las representan en su totalidad y que se comparan con la información obtenida a partir de la imagen desconocida. En este caso se hablaría de clasificación supervisada, frente a la clasificación no supervisada, donde se desconoce cualquier información previa acerca de las imágenes que se manejan.
2. Segmentación. Consiste en dividir una imagen en regiones significativas cuyas propiedades sean homogéneas [265], como se ilustra en la Figura 1.6. Esta descomposición en partes de la imagen tiene que ser consistente con

la percepción visual que una persona pueda tener de ellas. De manera análoga a lo que ocurre en el caso de la clasificación, existen dos enfoques básicos: segmentación supervisada y segmentación no supervisada.




Figura 1.6: Segmentación de imágenes aplicada a la detección de carreteras en un sistema de asistencia a la conducción de vehículos.

3. Identificación. El objetivo de la identificación de texturas es la discriminación, dentro de una imagen, de las regiones que tienen textura frente a aquellas que no la tienen [25, 130]. El interés de la identificación de texturas radica en las potenciales aplicaciones que tiene en el realce de imágenes y en la detección de defectos en tiempo real. Podría pensarse que la identificación de textura en una imagen no es más que un caso particular de segmentación. Sin embargo, nosotros consideramos que constituye un problema canónico con entidad propia puesto que se ha demostrado que en imágenes que contienen bordes o texturas que varían lentamente, las técnicas de segmentación no son las más adecuadas para la tarea de detectar la textura, con independencia del tipo de textura [26].
4. Síntesis. La síntesis de texturas consiste en crear a partir de una pequeña muestra de una textura una imagen de mayor tamaño con la misma textura [34, 67, 204], como se ilustra en la Figura 1.7. Los últimos avances en esta línea han permitido el desarrollo de complejos algoritmos capaces de generar una imagen a partir de un modelo 3D *-rendering-* que incorpore información de materiales, colores e iluminación [97].
5. Búsqueda automática de imágenes. Los sistemas de búsqueda y recuperación de imágenes tienen como finalidad encontrar imágenes digitales en bases de datos de gran tamaño [58, 154, 221]. Existen dos formas de abordar este problema: utilizar palabras clave para etiquetar cada una de las imágenes almacenadas en la base de datos o guardar información previamente extraída sobre su contenido visual. Esta última técnica, conocida habitualmente por su nombre en inglés, *Content Based Image Retrieval* (CBIR), es la que encuentra cabida en el ámbito del análisis de texturas. La implementación más extendida de los sistemas CBIR se denomina «consulta por imagen» (*query by image*). En esta técnica el usuario presenta al sistema una imagen de muestra y éste le devuelve como resultado las imágenes contenidas en la base de datos que más se parecen al patrón de búsqueda. La búsqueda de imágenes a partir de su contenido sólo se ha abordado de manera intensiva en los últimos años con la aparición de




Figura 1.7: Síntesis de texturas.

la web. En la Figura 1.8 se muestra el aspecto de la interfaz gráfica de un sistema de estas características, concretamente *img(Anaktisi)* [262].

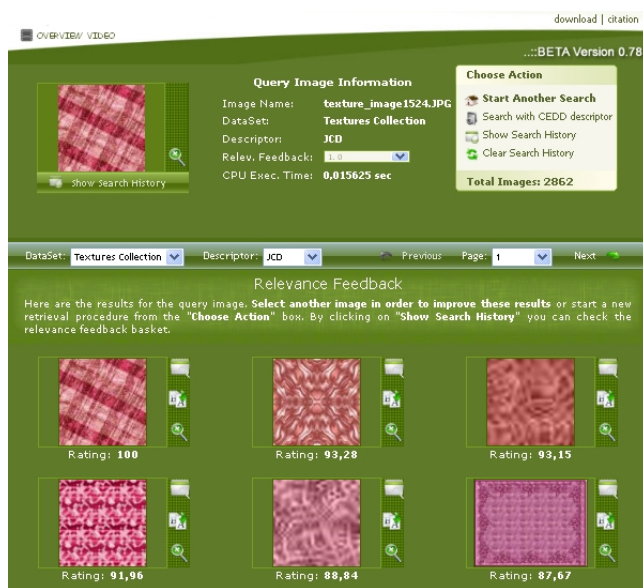


Figura 1.8: Interfaz gráfica de la herramienta de búsqueda de imágenes basada en contenido *img(Anaktisi)*.

6. Extracción de la forma a partir de la textura (*Shape from texture*). Consiste en reconstruir la forma de un objeto o determinar la orientación de una superficie a partir de ciertas características de su textura [76]. Existen estudios que demuestran que los observadores humanos utilizamos el gradiente de la textura como primer elemento en la deducción de la inclinación de una superficie y de la distancia relativa a una escena [226]. Ese gradiente indica la dirección de máxima variación del tamaño de las primitivas de textura y su ubicación espacial [15]. Es por ello que áreas disjuntas de una misma imagen se perciben como diferentes a pesar de que contengan

una textura similar, y de ahí que seamos capaces de recuperar información tridimensional a partir de imágenes bidimensionales. Conviene señalar que el desarrollo de un sistema capaz de imitar este comportamiento entraña grandes dificultades computacionales.



Figura 1.9: Extracción de la forma a partir de la textura.

7. Compresión. Existen algoritmos específicamente diseñados para minimizar la cantidad de datos necesarios para almacenar una imagen con textura. Se distinguen de los algoritmos clásicos de compresión de imágenes, como *Graphics Interchange Format* (GIF), *Joint Photographic Experts Group* (JPEG) o *Portable Network Graphics* (PNG), porque tratan de explotar la estructura estadística de las imágenes con textura para alcanzar mayores tasas de compresión y mayor velocidad. La mayoría de los compresores de texturas tienen pérdidas, es decir, descartan parte de la información para alcanzar mayores tasas de compresión, aunque esto no suele afectar en gran medida a la calidad final de la imagen resultante con respecto a la escena original. Por ejemplo, Beers *et. al* [23] propusieron un algoritmo basado en la técnica denominada *Vector Quantization* (VQ) que alcanzaba una tasa de compresión de hasta 35:1 con mínimas pérdidas de los detalles de la imagen original. En [49] se puede encontrar una revisión y discusión más extensa del trabajo desarrollado en relación con este problema.

### 1.3.2. Aplicaciones

El análisis de texturas ha encontrado numerosas aplicaciones en ámbitos muy dispares. Una revisión exhaustiva de las mismas excedería ampliamente el objetivo de este capítulo introductorio, por lo que en esta sección nos limitaremos a mostrar un abanico representativo de las posibilidades que ofrecen estas técnicas como disciplina de investigación aplicada.

Las primeras aplicaciones de las técnicas de análisis de texturas pertenecen al campo del análisis de terrenos [88, 255]. La conjunción entre la teledetección



y las técnicas de procesamiento digital de la imagen ha demostrado su idoneidad para determinar los usos del suelo o estimar los recursos naturales disponibles en una determinada región geográfica utilizando imágenes aéreas o de satélite [104, 263], como se muestra en la Figura 1.10(a). Otros ejemplos relevantes son el desarrollo de herramientas automáticas de gestión del territorio, el levantamiento de cartografía [162, 202], o la gestión de residuos agrícolas [2, 3].

De especial importancia resulta la utilización de la textura en el ámbito biomédico, donde debemos destacar los sistemas automáticos de ayuda al diagnóstico de enfermedades. Desde hace algunos años, la clasificación y la segmentación de imágenes médicas han demostrado ser herramientas muy útiles y fiables en este tipo de aplicaciones. La literatura al respecto es muy extensa: diagnóstico de cáncer de pulmón [124], cáncer de mama [171], obstrucción pulmonar [47], cáncer de hígado [105] y otras patologías hepáticas [197], leucemia [241], nódulos tiroideos [126], linfoma folicular [212], etc. También se han desarrollado sistemas CBIR, como la Herramienta de Recuperación de Imágenes Mamográficas por Análisis de Contenido para el Asesoramiento en el Diagnóstico del Cáncer de Mama (HRIMAC) [182], para simplificar la tediosa situación que se produce cuando un médico que dispone de la mamografía de una paciente necesita consultar otros casos, revisando una por una las imágenes almacenadas en soporte digital o físico, para conocer el diagnóstico y tratamiento recomendado, situación que ilustramos en la Figura 1.10(b).

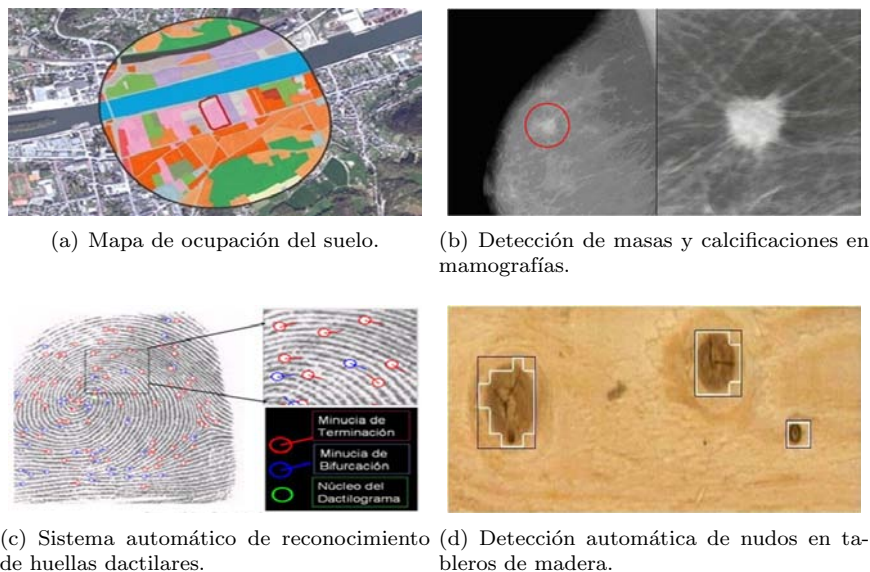


Figura 1.10: Ejemplos de aplicación del análisis de texturas.

Asimismo, los sistemas CBIR basados en el análisis de la textura han alcanzado una notable extensión como herramientas de apoyo a la detección y prevención del crimen. Probablemente, el ejemplo más conocido sea la búsqueda e identificación automática de huellas digitales – *Automatic Fingerprint Identification Systems (AFIS)*–, que ilustramos en la Figura 1.10(c), empleada por la mayoría de organismos policiales del mundo y en numerosos productos comerciales [111]. Otra de las aplicaciones relacionadas con la seguridad y la identificación

biométrica es la detección de caras. La cantidad de algoritmos propuestos a lo largo de las últimas décadas prácticamente nos permite afirmar que ha constituido por sí sola una nueva área de investigación [5, 20, 114, 219, 220, 239]. En los últimos años también están atrayendo gran atención los sistemas de identificación mediante el iris [156]. Con el objetivo de reducir el ingente volumen de información que manejan estas aplicaciones se han desarrollado algoritmos especializados de compresión de la textura, como la *Wavelet/Scalar Quantization* (WSQ) [37, 38].

Por último, las aplicaciones industriales también ocupan un lugar destacado dentro del conjunto de posibilidades que ofrece el análisis de texturas. La detección de productos defectuosos, que ilustramos en la Figura 1.10(d), el control de calidad o la gestión automática de catálogos son tres de las más habituales. Podemos mencionar ejemplos en sectores productivos muy variados, como electrónica de consumo [99] y semiconductores [236], textil [21, 216], madera [55], automóviles [108], papel [163], cerámica [35, 36, 198], cítricos [249], corcho [70], extracción de minerales [190] o piedras ornamentales [223].

En general, la mayoría de las aplicaciones del análisis de texturas manejan imágenes de naturaleza óptica. No obstante, debemos dejar constancia de que muchos de los usos del análisis de texturas se basan en imágenes de naturaleza no óptica, es decir, imágenes que miden otros parámetros distintos a la intensidad de la luz reflejada, puesto que hay fenómenos físicos que no se revelan en la banda visible del espectro electromagnético, pero que en otras bandas son patentes, o que incluso no tienen naturaleza electromagnética. Nos referimos a técnicas como la resonancia magnética o *Magnetic Resonance Images* (MRI), los rayos X, uno de cuyos usos más importantes es la tomografía axial o *Computerized Axial Tomography* (CAT), las imágenes de rayos gamma o de las bandas infrarroja, ultravioleta o radio. Fuera del dominio electromagnético podríamos mencionar las imágenes acústicas o de la microscopía electrónica [78].

## 1.4. Descriptores de textura

El éxito de cualquier sistema que se sustente en el análisis de texturas para obtener una solución a un determinado problema dependerá principalmente de la etapa de extracción de características. Esta tarea consiste en representar la textura mediante un conjunto de valores numéricos –comúnmente referidos como vector de características– que se calculan a partir de ciertos atributos de la imagen y en función de los cuales debe resultar posible la discriminación de distintos tipos de textura.

La ingente cantidad de espacios de características que se han propuesto hasta el momento, que se ha calificado recientemente como una *galaxia de características de textura* [257], explica la dificultad que entraña la categorización inequívoca de los mismos. Además, tal sobreabundancia de modelos dificulta enormemente la tarea de establecer cuáles son aquellos que ofrecen las mejores prestaciones. En los siguientes apartados abordaremos brevemente estos dos asuntos.

### 1.4.1. Taxonomía

Al igual que no existe una única definición para la textura, tampoco se ha producido un acuerdo entre los autores de referencia en esta materia sobre el modo en el que se podrían clasificar los distintos tipos de descriptores. La principal dificultad con la que tropieza cualquier intento de categorización es que la mayor parte de los descriptores de textura presentan rasgos de más de una categoría, por lo que en muchos casos la asignación a una u otra resulta discutible. A continuación se exponen, por orden cronológico de aparición en la literatura, algunas de las clasificaciones más extendidas con el objetivo de poner de relieve la dificultad que entraña una categorización bien estructurada de los descriptores.

- Haralick [89] y van Gool *et al.* [79] establecieron una división general –que ha gozado de gran aceptación– entre descriptores estadísticos y estructurales. Los primeros serían adecuados para el análisis de microtexturas, mientras que los segundos sólo darían buenos resultados con texturas que pueden representarse adecuadamente mediante primitivas y sus reglas de ubicación. En su argumentación, ellos mismos admiten que, en gran medida, esta distinción resulta artificial, ya que no existe una frontera clara entre ambas categorías.
- Wu y Chen [256] también parten del enfoque clásico de los anteriores autores, sugiriendo además una subdivisión de las características estadísticas en cinco tipos: métodos de dependencia del nivel de gris, características basadas en la frecuencia espacial, características basadas en modelos estocásticos, métodos de filtrado y descriptores heurísticos. Estas últimas se caracterizan por proporcionar buenos resultados en aplicaciones concretas, a pesar de no estar basadas en un modelo matemático o psicofísico.
- Tuceryan y Jain [238] aportan una clasificación novedosa con respecto a lo publicado hasta ese momento. En su trabajo hablan de descriptores estadísticos, geométricos, basados en modelo y finalmente los que se fundamentan en algoritmos de procesamiento de la señal. Los descriptores geométricos serían una generalización de los métodos estructurales comentados anteriormente. Los métodos basados en modelo asumen que la textura se ajusta a un determinado modelo estocástico y la representan mediante los parámetros que definen dicho modelo. Dentro de esta categoría se incluirían técnicas como los *Markov Random Fields* (MRF) [56] o los fractales [125]. Los métodos que se basan en el procesamiento de la señal se fundamentan en el análisis de la frecuencia que realiza el cerebro humano sobre las imágenes que percibe.
- Sonka *et al.* [224] consideran únicamente la existencia de descriptores estadísticos, sintácticos e híbridos. Tanto los métodos sintácticos como los híbridos serían adecuados para caracterizar texturas a cuyas primitivas se les pueda asignar una etiqueta identificativa, que en general no se referirá únicamente a la distribución espacial de intensidad sobre un determinado conjunto de píxeles, sino que definirá su significado mediante la utilización de términos del lenguaje natural.
- En uno de los trabajos más recientes y completos al respecto, Xie y Mirmehti [257] plantean una categorización similar a la de Tuceryan y Jain,

distinguiendo entre métodos estadísticos, estructurales, basados en modelo y basados en el procesamiento de la señal. La novedad principal que aporta esta categorización es que, por primera vez, se admite la clasificación de un mismo descriptor como perteneciente a una o más categorías.

En nuestra opinión, de lo anterior se deduce que, en realidad, todas las técnicas propuestas se podrían unificar bajo el epígrafe que en la bibliografía se ha dado en denominar como «descriptores estadísticos». Dicha afirmación no debe extrañarnos dado que esta es la única categoría sobre cuya existencia existe consenso científico y además, concuerda totalmente con la naturaleza de la textura, que como mencionábamos en la Sección 1.1, es inherentemente aleatoria. Admitimos igualmente que los «descriptores estructurales» podrían tener razón de ser bajo determinadas circunstancias, principalmente cuando nos referimos al análisis de texturas de origen artificial, pero sin olvidar en ningún momento que suponen un caso particular de los primeros. La existencia de estos dos tipos de descriptores es consistente con la descomposición jerárquica de la textura en macro y microtextura, propugnada por diversas teorías psicofísicas [54, 231]. Finalmente, queremos llamar la atención sobre el hecho de que ninguna de las categorizaciones que hemos revisado es plenamente satisfactoria ya que en todas ellas se produce solapamiento entre categorías.

#### 1.4.2. Estudios comparativos

Uno de los principales retos actuales del análisis de texturas es la determinación del descriptor óptimo en términos de poder de discriminación intrínseco, es decir, con independencia de la aplicación en la que se utilice. La búsqueda del descriptor óptimo es una tarea extraordinariamente compleja, debido en gran medida a la disponibilidad de un amplísimo catálogo de descriptores de textura. Diferentes investigadores se han propuesto este objetivo mediante la realización de estudios comparativos. A continuación describimos brevemente aquellos que consideramos más interesantes:

- Weszka *et al.* [255] presentaron una técnica a la que denominaron *Gray-Level Difference* (GLD) y concluyeron que sus prestaciones eran similares a las de los modelos *Spatial Gray-Level Dependence Method* (SGLDM) [88] y *Gray Level Run Length* (GLRL) [74] y mejores que las de los métodos basados en el análisis de Fourier [78].
- Connors y Harlow [53] completaron el trabajo anterior comparando desde un punto de vista teórico los modelos SGLDM, GLRL, GLD y *Power Spectral Method* (PSM) [149].
- Siew *et al.* [216] adoptaron sin embargo un enfoque aplicativo al estudiar SGLDM, GLD, GLRL y *Neighboring Gray Level Dependence Statistics* (NGLDS) [229] para caracterizar el desgaste de alfombras.
- Du Buf *et al.* [42] se interesaron por las características de Haralick [88], las máscaras de Laws [145], las transformadas lineales locales [243], la dimensión fractal [191], el *General Operator Processor* (GOP) [81], el *Number of Gray Level Extrema* (NGLE) [168] y la integración curvilínea [16] en tareas de segmentación. Según estos autores, los resultados obtenidos por

todas estas técnicas son parecidos, destacando ligeramente los tres primeros métodos sobre los demás.

- Según Ohanian y Dubes [173], las matrices de coocurrencia obtienen mejores resultados que los filtros de Gabor [27, 109], los MRF [56] y las técnicas fractales [133].
- Randen y Husøy [201] completaron una rigurosa revisión dedicada a los principales descriptores de textura basados en filtrado, lo que supuso una importante novedad. Su objetivo era estudiar el comportamiento de una familia concreta de descriptores para determinar cual de dichas técnicas presentaba un mejor comportamiento con respecto a tres colecciones de imágenes diferentes. Como referencia, en dicha comparativa se incluyeron asimismo dos técnicas que, según su criterio, no realizan ningún tipo de filtrado sobre las imágenes: las matrices de coocurrencia y los modelos autorregresivos [165].
- Vince et al. [250] consideran que las características de Haralick son mejores que las máscaras de Laws, el *Texture Spectrum* (TS) [94] y las *Neighborhood Gray Tone Difference Matrices* (NGTDM) [12].
- Singh y Sharma [217] utilizaron las bases de datos MeasTex [222] y Vistex [251] para comparar varios descriptores de textura. Concluyeron que la mejor tasa de acierto se obtenía utilizando las matrices de coocurrencia. En un trabajo posterior plantearon un estudio comparativo de ocho métodos diferentes [214, 218].
- Para concluir esta enumeración, Poonguzhali y Ravindran [197] se centraron en las máscaras de Laws, la autocorrelación, la *Edge Frequency* (EF) [237], los filtros de Gabor y las matrices de coocurrencia.

Una vez analizados estos trabajos, debemos destacar un problema del que adolecen todos ellos: la imposibilidad de extrapolación de los resultados que obtienen. Esta carencia se manifiesta como consecuencia de dos limitaciones de partida. En primer lugar, resulta inviable en la práctica efectuar una comparativa en la que se consideren simultáneamente todos los descriptores de textura propuestos hasta la fecha. La solución que se suele adoptar para tratar de soslayar esta situación es la selección de unas pocas técnicas representativas o la restricción del análisis comparativo a una única familia de descriptores. En segundo lugar, esos resultados están fuertemente condicionados por las colecciones de imágenes que emplean. Cada trabajo maneja unas determinadas bases de datos, diferentes de las utilizadas por otras comparativas similares, y de este modo en la literatura de referencia es posible encontrar resultados contradictorios [214, 218]. En este sentido son paradigmáticas las conclusiones a las que llegan Varma y Zisserman [246, 247], que rebaten la idea ampliamente extendida de que los métodos basados en transformadas locales obtenidas mediante operadores de convolución son superiores a los que estiman la función de densidad de probabilidad conjunta de una región de píxeles sin llevar a cabo ningún tipo de filtrado [243].

De este modo, como conclusión final, podemos afirmar que, a pesar de lo interesante que resultaría conocer cuáles son los descriptores de textura más adecuados, la elaboración de una tabla clasificatoria de técnicas de análisis de

texturas en función de sus prestaciones, usando algún índice cuantitativo –como por ejemplo la tasa de acierto– como criterio de ordenación, continúa siendo una tarea ardua y compleja que constituye una línea de investigación todavía abierta, como lo demuestra la abundante bibliografía que sigue apareciendo al respecto.

## 1.5. Interés de la tesis

Como hemos demostrado a lo largo de este capítulo introductorio, el análisis de texturas sigue albergando numerosas cuestiones por resolver. En primer lugar, el concepto mismo de textura visual es difuso y todavía no se ha conseguido entender por completo, lo que explica las dificultades y controversias que suscita su definición. En segundo lugar, se han propuesto numerosos modelos matemáticos de la textura que buscan una caracterización cuantitativa, pero que en su mayoría son soluciones *ad hoc* cuya generalización es inviable al estar basadas en consideraciones de tipo empírico, lo que dificulta la tarea de determinar cuál es el descriptor que permite obtener los mejores resultados. Poner orden en este vasto universo de descriptores de textura, es decir, establecer una categorización coherente, tampoco ha generado un acuerdo entre los autores de referencia en esta materia. Por último, se han publicado numerosos estudios comparativos cuyo objetivo principal suele ser demostrar la superioridad de un determinado descriptor frente a otros que conforman un conjunto más o menos extenso, pero en nuestra opinión, no son lo suficientemente representativos y rigurosos como para extraer conclusiones de alcance.

La búsqueda de respuestas a todas estas incógnitas es crucial para el análisis de texturas y ha motivado el desarrollo de un volumen ingente de trabajo en términos de investigación y aplicaciones en muchos ámbitos, como el biomédico, el industrial, la robótica, la seguridad, la teledetección, etc. Dentro de esta línea, consideramos que esta tesis se sitúa en el estado del arte actual, ya que aporta las novedades que enumeramos a continuación.

1. Hemos desarrollado un modelo teórico que evidencia la similitud conceptual que comparten numerosas técnicas de caracterización de la textura tratadas hasta el momento de manera independiente. Todos estos descriptores a los que nos referimos, estiman la distribución conjunta de la probabilidad mediante histogramas de patrones equivalentes. Hasta el momento no se había planteado un estudio de estas técnicas desde un punto de vista general e integrador como el que desarrollamos en este trabajo. Hemos constatado que desde este marco teórico que proponemos se pueden explicar muchos de los descriptores ya conocidos, así como desarrollar otros nuevos, como efectivamente hemos logrado.
2. Para demostrar la validez y potencia de este modelo proponemos una particularización del mismo que se concreta en una nueva familia de descriptores de textura, a la que hemos denominado *Binary Gradient Contours* (BGC). Con estos descriptores hemos obtenido excelentes resultados en los experimentos de clasificación que hemos efectuado, superando incluso a técnicas ampliamente referenciadas y documentadas en la literatura. Además, hemos realizado un estudio teórico que nos ha permitido explicar en términos de entropía las buenas prestaciones de dichos descriptores.

3. Hemos realizado una amplia comparativa que incluye todos aquellos descriptores que encajan en el modelo unificado propuesto. Se ha desarrollado un banco de pruebas formado por 10 bases de datos que incluyen colecciones de imágenes digitales procedentes de diversas fuentes. Este es, por lo que sabemos, el mayor análisis comparativo que se ha completado dentro de esta línea de investigación, lo que supone que las conclusiones que se extraen de nuestro trabajo adquieren un carácter más general que las de otras publicaciones anteriores.

Hemos estructurado esta memoria de tesis doctoral del siguiente modo. En el Capítulo 2 se introduce el modelo teórico que permite unificar bajo una estructura matemática común los descriptores que se basan en el establecimiento de una relación de equivalencia entre patrones para representar la textura mediante un histograma de dimensión reducida. El Capítulo 3 desarrolla la nueva familia de descriptores de textura que hemos creado como particularización del marco teórico que establecíamos en el capítulo anterior. En el Capítulo 4 se describe la metodología experimental que hemos seguido y se comentan los resultados obtenidos –recogidos en detalle en el Apéndice A–, para finalizar en el Capítulo 5 con las conclusiones.

## Capítulo 2

# Modelo unificado

La caracterización de la textura sigue siendo a día de hoy, y probablemente lo seguirá siendo en el futuro más inmediato, un problema muy complejo para el que todavía no se ha encontrado una solución de carácter global. La mayor parte del esfuerzo investigador invertido hasta el momento se ha centrado en aportar soluciones a problemas concretos. El objetivo principal de estos trabajos es demostrar que un nuevo descriptor de textura resulta más adecuado para el análisis de un determinado tipo de imágenes que otros ya existentes. Esta filosofía ha motivado que se hayan desarrollado de manera independiente numerosos descriptores de índole muy diversa, lo que explica en gran medida las dificultades que presenta la categorización de los descriptores de textura propuestos hasta el momento, como ya se apuntó en la Sección 1.4.1.

En este capítulo proponemos un modelo general que unifica un amplio conjunto de descriptores de textura. Hasta la fecha se había considerado que estas técnicas pertenecían a categorías diferentes, obviando que en realidad, todas ellas comparten el mismo principio. La principal novedad de este marco teórico radica en la identificación y formulación de este rasgo común: el establecimiento de una relación de equivalencia entre patrones para representar la textura mediante un histograma de dimensión reducida. La particularidad de cada técnica reside en el mecanismo de reducción de la dimensión del histograma, es decir, en la definición de la relación de equivalencia. Como se verá, el modelo teórico propuesto es simple y compacto y está abierto a la incorporación de nuevos métodos que se puedan desarrollar en el futuro.

### 2.1. Histograma de patrones

Los descriptores estadísticos de textura han gozado tradicionalmente de una gran aceptación debido a que proporcionan una caracterización precisa a un coste computacional razonable. El fundamento de estas técnicas consiste en representar la textura a través de la distribución espacial conjunta de la intensidad en el entorno de un píxel. En el caso de una imagen de textura estacionaria, es decir, una imagen que contenga un único tipo de textura, esta idea se podría implementar de manera directa por medio de la función de distribución de probabilidad de los posibles patrones en escala de grises presentes en la imagen. En el contexto de esta tesis un patrón de textura se define como una disposición



particular de los niveles de gris en una región determinada. Para obtener una estimación de esta distribución de probabilidad se suele calcular un histograma que cuantifica la frecuencia de aparición de los diferentes patrones presentes en la imagen. A tal efecto, se efectúa un barrido secuencial de toda la imagen con una ventana deslizante, con desplazamientos incrementales de un píxel por filas y columnas, y en cada posición se incrementa en una unidad la componente del histograma correspondiente al patrón detectado. Con carácter general dicha ventana abarcará una región rectangular. Sin embargo, para evitar que unas direcciones prevalezcan sobre otras, la elección más habitual es emplear ventanas cuadradas, lo que garantiza un análisis isotrópico. Además, resulta conveniente que el número de filas o columnas sea impar para que el centro de la ventana coincida con un píxel de la imagen. La ventana de tamaño  $3 \times 3$  píxeles es la que cumple estas premisas con una menor complejidad computacional y por ello, ha sido y es con diferencia, la opción más extendida para el cálculo de descriptores de textura. Este hecho justifica nuestra decisión de limitar el ámbito de esta tesis al estudio de descriptores basados en ventanas  $3 \times 3$ .

A pesar de la simplicidad conceptual de este enfoque, su aplicación inmediata resulta inviable dado que el número de componentes del histograma es excesivamente elevado, incluso para ventanas de tamaño reducido, como es el caso  $3 \times 3$ . Es bien sabido que la descripción de imágenes mediante histogramas de gran dimensión proporciona una estimación poco fiable de la distribución subyacente y ofrece un poder de discriminación prácticamente nulo [66]. Para resolver esta dificultad, se han propuesto numerosos métodos de reducción de la dimensión de los histogramas [94, 114, 136, 157, 180, 211, 261], y aunque todas estas técnicas se basan en el mismo principio, no conocemos por el momento ningún marco teórico que las integre y formalice de manera general. Una de las aportaciones de esta tesis será precisamente proponer un nuevo modelo teórico capaz de unificar y sintetizar mediante una notación compacta los principios comunes a este tipo de descriptores. El uso de una notación unificada permitirá resaltar los fuertes lazos que, como de hecho demostraremos, existen entre estos modelos de textura.

La Figura 2.1 sintetiza el marco conceptual que proponemos, cuya idea central consiste en considerar que los procedimientos de reducción de la dimensión del histograma pueden interpretarse como una correspondencia definida sobre el conjunto de posibles patrones en escala de grises de manera tal que a cada patrón se le asigne un índice entero. Esta correspondencia induce una partición del conjunto de patrones en grupos de *patrones equivalentes*, es decir, todos aquellos patrones a los que se les asigna el mismo índice. La reducción de la dimensión del histograma se consigue agregando en una misma componente del histograma las frecuencias de aparición de todos los patrones que forman una clase de equivalencia.

Antes de abordar el estudio del marco teórico conviene acotar el conjunto de descriptores de textura que se adaptan al principio que acabamos de exponer. Tomando como referencia la clasificación de Xie y Mirmehdi [257], que agrupan los métodos de caracterización de la textura en cuatro categorías diferentes – estadísticos, estructurales, basados en modelo y procesamiento de la señal –, la mayoría de las técnicas que incluimos en el modelo tendrían un carácter eminentemente estadístico, aunque los límites del modelo teórico que proponemos no coinciden exactamente con los de la categoría de técnicas estadísticas, puesto que engloba descriptores de naturaleza híbrida. En este sentido, nuestro traba-

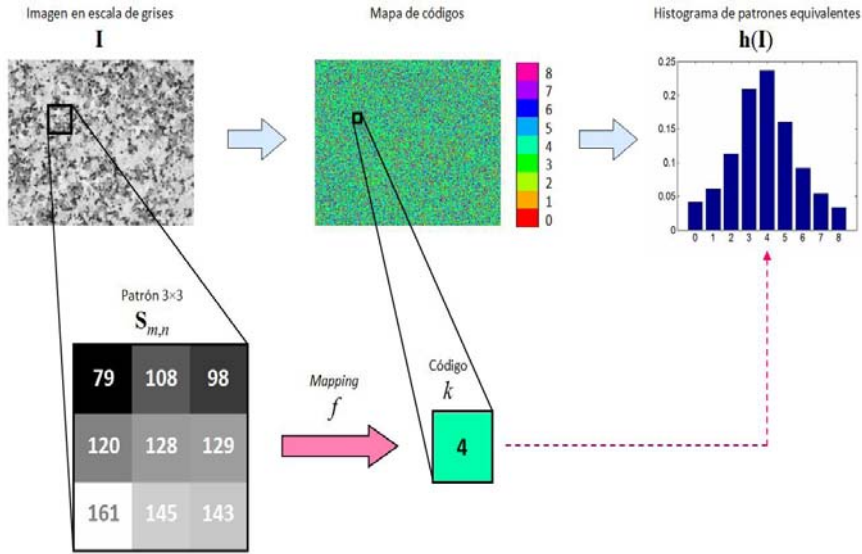


Figura 2.1: Representación esquemática de la caracterización de textura mediante histogramas de patrones equivalentes.

jo sería análogo al ya clásico de Randen y Husøy [201], en donde también se realizaba un estudio comparativo riguroso y exhaustivo de una familia concreta de descriptores. En aquel caso se trataba de los basados en filtrado, mientras que nuestro trabajo se ocupa de las técnicas de caracterización de la textura basadas en histogramas de patrones equivalentes.

Existen descriptores de textura inspirados en el principio fundamental que acabamos de exponer que incorporan una o varias etapas adicionales al proceso de obtención del histograma de patrones equivalentes, que mostramos en la Figura 2.1. Dichos descriptores, aunque no forman parte del modelo teórico propuesto, guardan una estrecha relación con él, lo que les hace merecedores de una particular atención en la presente tesis. Por ello, en la Sección 2.4 propondremos una serie de direcciones en las que se podría extender nuestro modelo para integrar a estos descriptores, y describiremos brevemente una amplia selección de los mismos.

## 2.2. Formalización del modelo

Para describir adecuadamente el marco teórico que hemos propuesto, es preciso comenzar definiendo la notación que se empleará a partir de ahora a lo largo de este texto. Sea  $I$  una matriz de  $M$  filas y  $N$  columnas que representa las intensidades de los píxeles de una imagen cuantizada a  $G$  niveles de gris, e  $I_{m,n} \in \{0, 1, \dots, G-1\}$  la intensidad del píxel situado en la  $m$ -ésima fila y en la  $n$ -ésima columna. Denotaremos como  $S_{m,n}$  al recorte cuadrado de  $3 \times 3$  píxeles de la imagen  $I$  centrado en el píxel  $(m, n)$ :

$$\mathbf{S}_{m,n} = \begin{bmatrix} I_{m-1,n-1} & I_{m-1,n} & I_{m-1,n+1} \\ I_{m,n-1} & I_{m,n} & I_{m,n+1} \\ I_{m+1,n-1} & I_{m+1,n} & I_{m+1,n+1} \end{bmatrix} \quad (2.1)$$

Para simplificar la notación eliminaremos la dependencia de  $(m, n)$  de la ecuación anterior, sin pérdida de generalidad. De este modo  $\mathbf{S}$  será una matriz que representará las intensidades de los píxeles de una vecindad cuadrada genérica de tamaño  $3 \times 3$ . Sea  $I_c$  el nivel de gris del píxel central e  $I_j$  los niveles de gris de los píxeles de la periferia ( $j \in \{0, 1, \dots, 7\}$ ), que se distribuyen de la siguiente manera:

$$\mathbf{S} = \begin{bmatrix} I_7 & I_6 & I_5 \\ I_0 & I_c & I_4 \\ I_1 & I_2 & I_3 \end{bmatrix} \quad (2.2)$$

Denotaremos como  $\mathcal{M}_{3 \times 3, G}$  al conjunto de todas las posibles instancias definidas por la Ecuación 2.2. Dado que la profundidad de digitalización de la mayoría de cámaras digitales disponibles en el mercado de gran consumo es de 8 bits,  $G$  suele tomar el valor  $2^8$ , lo que implica que las intensidades de los píxeles se cuantizan en 256 niveles. De manera inmediata se deduce que el número de patrones  $3 \times 3$  en escala de grises diferentes viene dado por:

$$\#\mathcal{M}_{3 \times 3, 256} = 256^9 = 2^{72} \quad (2.3)$$

donde  $\#$  significa “cardinal de”. A partir de la Ecuación 2.3 se concluye que la descripción de la textura por medio de la distribución conjunta de las intensidades de los píxeles que conforman un vecindario de tamaño  $3 \times 3$  implica la utilización de un vector de características de aproximadamente  $4,7 \times 10^{21}$  componentes. Imaginemos que se pretende describir la textura de una imagen con uno de estos histogramas. Teniendo en cuenta que el número de posibles patrones es varios órdenes de magnitud mayor que el número de píxeles de una imagen, incluso en el caso de imágenes de alta resolución, muchos patrones no aparecerían ni una sola vez, con lo cual se obtendría un histograma disperso, con un poder de discriminación prácticamente nulo [155]. Además, la memoria necesaria para almacenar cada uno de estos histogramas desbordaría la capacidad de los ordenadores actualmente disponibles. Para modelar satisfactoriamente la textura mediante una distribución de patrones, es preciso reducir la dimensión del histograma. A tal efecto nosotros proponemos la partición de  $\mathcal{M}_{3 \times 3, G}$  en  $K$  grupos de patrones. La reducción de la dimensión se puede alcanzar de manera directa combinando en una única barra aquellas barras del histograma original que se corresponden con los patrones que pertenecen a un mismo grupo. La partición se puede formalizar adecuadamente mediante un mapeado que asigne a cada patrón un índice entero no negativo que identifique de manera unívoca el grupo al que pertenece y que se utilizará como etiqueta de la barra correspondiente en el histograma:

$$\begin{aligned} f : \mathcal{M}_{3 \times 3, G} &\longrightarrow \mathbb{N} \\ \mathbf{S} &\longmapsto k = f(\mathbf{S}) \end{aligned} \quad (2.4)$$

La función anterior establece una relación de equivalencia en  $\mathcal{M}_{3 \times 3, G}$ , representada por  $\sim$ :

$$\mathbf{S}_1 \sim \mathbf{S}_2 \Leftrightarrow f(\mathbf{S}_1) = f(\mathbf{S}_2) \quad \forall \mathbf{S}_1, \mathbf{S}_2 \in \mathcal{M}_{3 \times 3, G} \quad (2.5)$$

Idealmente esta relación de equivalencia debe ser tal que los patrones próximos entre sí según algún criterio significativo, como la similitud desde el punto de vista de la percepción visual, pertenezcan a la misma clase de equivalencia. La función  $f$  se debe diseñar de manera tal que el número de grupos de patrones equivalentes sea mucho menor que el número de posibles patrones ( $K \ll G^9$ ). En este caso la textura se puede caracterizar adecuadamente mediante la distribución de los grupos de patrones equivalentes en vez de la distribución de los patrones originales.

Sea  $\mathcal{K}$  el rango de  $f$  [254]:

$$\mathcal{K} = f(\mathcal{M}_{3 \times 3, G}) \quad (2.6)$$

y  $K$  el número de grupos de patrones diferentes, es decir, el número de clases de equivalencia:

$$K = \#\mathcal{K} \quad (2.7)$$

La partición del universo de patrones en escala de grises que se pueden producir en una ventana de tamaño  $3 \times 3$  se puede expresar tal y como se indica en la siguiente expresión:

$$\mathcal{M}_{3 \times 3, G} = \bigcup_{k \in \mathcal{K}} \mathcal{M}_{f, k} \quad (2.8)$$

donde la familia de subconjuntos  $\{\mathcal{M}_{f, k} \mid k \in \mathcal{K}\}$  es disjunta por pares, y cada subconjunto se define como:

$$\mathcal{M}_{f, k} = \{\mathbf{S} \in \mathcal{M}_{3 \times 3, G} \mid f(\mathbf{S}) = k\} \quad (2.9)$$

No es necesario que los índices generados por  $f$  sean correlativos. Sin embargo, para simplificar la notación que se manejará de ahora en adelante, podemos considerar –sin pérdida de generalidad– que los códigos que se asignan a los diferentes  $\mathcal{M}_{f, k}$  están definidos del siguiente modo:

$$\mathcal{K} = \{0, 1, 2, \dots, K - 1\} \quad (2.10)$$

En definitiva, en el modelo que proponemos, la relación de equivalencia que induce la función  $f$  permite la representación de una imagen con textura  $\mathbf{I}$  por medio de un vector  $K$ -dimensional  $\mathbf{h}_f(\mathbf{I})$ , en el que la componente  $k$ -ésima viene dada por:

$$h_{f, k}(\mathbf{I}) = \frac{\#\{(m, n) \mid f(\mathbf{S}_{m, n}) = k\}}{(M - 2) \times (N - 2)} \quad (2.11)$$

Debe tenerse en cuenta que, con el propósito de que la subimagen  $\mathbf{S}_{m, n}$  esté totalmente contenida en  $\mathbf{I}$ , su píxel central no puede situarse en el borde de la imagen y por tanto, la Ecuación 2.11 debe satisfacer que  $2 \leq m \leq M - 1$  y  $2 \leq n \leq N - 1$ .

### 2.3. Tipos de correspondencias

A continuación, como resultado de un exhaustivo trabajo de revisión bibliográfica, presentamos un catálogo formado por las principales técnicas de descripción de la textura empleadas hasta el momento que se adaptan al marco teórico que desarrollamos a lo largo de este capítulo. El principio subyacente en el que se basan todas ellas es la caracterización de la textura por medio de histogramas de patrones locales de dimensión reducida. La unificación de todas estas técnicas supone una novedad, ya que se ponen de manifiesto una metodología y un grado de generalización que permiten explicar de manera uniforme ideas, en muchos casos aparentemente inconexas, que en realidad comparten un fundamento conceptual común.

El procedimiento empleado para la construcción del histograma de patrones admite sin embargo diversas soluciones. Es por ello que hemos realizado una categorización de las técnicas incluidas en este trabajo estableciendo tres grupos diferentes, a cada uno de los cuales dedicaremos un apartado. Para demostrar la validez del marco teórico particularizaremos la relación de equivalencia genérica definida en la Ecuación 2.4 para cada uno de los descriptores considerados, es decir, explicitaremos la forma en que cada modelo asigna códigos a los patrones locales.

Antes de comenzar la exposición de cada una de estas tres categorías, conviene definir tres funciones que desde este momento se van a emplear con asiduidad cuando presentemos la formalización algorítmica de cada técnica. Nos referimos respectivamente a la delta de Dirac normalizada (Ecuación 2.12), la función de umbralización binaria (Ecuación 2.13) y la función de umbralización ternaria (Ecuación 2.14), que se pueden expresar con respecto a una variable genérica  $x$  de la siguiente forma:

$$\delta(x) = \begin{cases} 1, & \text{si } x = 0 \\ 0, & \text{en otro caso} \end{cases} \quad (2.12)$$

$$\xi(x) = \begin{cases} 1, & \text{si } x \geq 0 \\ 0, & \text{si } x < 0 \end{cases} \quad (2.13)$$

$$\eta_{\Delta}(x) = \begin{cases} 0, & \text{si } x < -\Delta \\ 1, & \text{si } -\Delta \leq x \leq \Delta \\ 2, & \text{si } x > \Delta \end{cases} \quad (2.14)$$

#### 2.3.1. Marginalización

El fundamento de los descriptores pertenecientes a esta categoría consiste en estimar una función de densidad de probabilidad conjunta a partir de una proyección de esta distribución multidimensional, que en el caso de ventanas de tamaño  $3 \times 3$  tiene nueve dimensiones, sobre un subespacio de menor dimensión. La forma más habitual de implementar la marginalización es descartar todas las relaciones posibles entre las intensidades de los píxeles vecinos menos una.

Las matrices de coocurrencia de Haralick, frecuentemente denominadas como *Grey-Level Co-occurrence Matrices* (GLCM) [88], son el representante más

popular dentro de esta categoría. Una matriz de coocurrencia estima la probabilidad de que una pareja de píxeles separados por un vector desplazamiento  $\delta\mathbf{r} = (\delta m, \delta n)$  presente una determinada distribución de intensidad. Si designamos la posición de los dos píxeles por  $(m, n)$  y  $(m + \delta m, n + \delta n)$ , y llamamos  $g_1$  y  $g_2$  a sus respectivos niveles de intensidad, donde  $0 \leq g_1, g_2 \leq G - 1$ , el elemento correspondiente de la matriz se puede expresar de la siguiente forma:

$$\mathbf{M}_{\delta m, \delta n}(g_1, g_2) = \frac{\#\{(m, n) \mid I_{m,n} = g_1 \wedge I_{m+\delta m, n+\delta n} = g_2\}}{(M - |\delta m|) \times (N - |\delta n|)} \quad (2.15)$$

Debe advertirse que el factor de normalización de la ecuación anterior es ligeramente diferente del que aparecía en la Ecuación 2.11. La razón que explica este hecho es que en el cálculo de las matrices de coocurrencia no se tienen en cuenta los nueve píxeles de la ventana  $3 \times 3$  sino solamente dos, y por consiguiente el número de filas y columnas de la imagen que deben tomarse en consideración será mayor o igual que  $(M - 2) \times (N - 2)$ .

A simple vista puede parecer que las matrices de coocurrencia no guardan relación alguna con la familia de descriptores de textura objeto de la presente tesis, aunque, como mostraremos inmediatamente, encajan perfectamente en el marco teórico que proponemos. Dado que la intensidad de un píxel puede tomar  $G$  valores diferentes, el número de posibles patrones distintos que se pueden obtener mediante una pareja de píxeles es  $G^2$ . Consideremos que uno de los píxeles de la pareja es el que ocupa la posición central de la ventana de tamaño  $3 \times 3$  y el otro es un píxel cualquiera de la periferia, cuyos respectivos niveles de intensidad son  $I_c$  e  $I_j$ , tal como hemos definido en la Ecuación 2.2. En nuestro modelo las matrices de coocurrencia se expresan como una correspondencia denominada **COOC** $_{3 \times 3}$ , que asigna el mismo código si y sólo si la pareja de píxeles considerados presentan simultáneamente los mismos valores de intensidad en ambos píxeles, y cuya expresión matemática detallamos en la Tabla 2.1. Esta reformulación de las matrices de coocurrencia como un histograma de patrones equivalentes en realidad no es más que una reordenación de los  $G^2$  elementos de la matriz de coocurrencia, lo que demuestra nuestra hipótesis de que las matrices de coocurrencia se basan en el mismo principio subyacente que los demás miembros de la familia de descriptores de textura que estudiamos en esta tesis.

Las matrices de coocurrencia adolecen de una serie de limitaciones. En primer lugar son descriptores paramétricos, pues dependen del vector de desplazamiento considerado, y desafortunadamente hasta la fecha no se ha propuesto una solución satisfactoria al problema de elegir el valor óptimo de  $\delta\mathbf{r}$ . Si bien es cierto que en algunos casos particulares las matrices de coocurrencia correspondientes a diferentes vectores  $\delta\mathbf{r}$  pueden presentar valores similares, en general cabe esperar un fuerte variación. Por otra parte, para un  $\delta\mathbf{r}$  cualquiera, las matrices de coocurrencia no suelen ser simétricas, y por consiguiente, para una imagen y su simétrica, en general se obtendrían matrices de coocurrencia distintas. Por último, es preciso señalar que las matrices de coocurrencia no son invariantes frente a rotaciones de las imágenes. Para paliar estos inconvenientes se han incorporado diversas modificaciones a la idea original. La invarianza a simetría se consigue sumando una matriz de coocurrencia con su traspuesta y dividiendo entre dos [54]. Por su parte, la invarianza a rotación se consigue promediando las matrices de coocurrencia correspondientes a varios vectores

Tabla 2.1: Correspondencias basadas en marginalización.

Modelo	$f(\mathbf{S})$	Parámetros	$K$	Referencias
COOC $2_{3 \times 3}$	$G \times I_c + I_j$	$j$	$G^2$	[184]
COOC $3_{3 \times 3}$	$G^2 \times I_c + G \times I_{j_1} + I_{j_2}$	$j_1, j_2$	$G^3$	[6]
GLD $3_{3 \times 3}$	$ I_c - I_j $	$j$	$G$	[255]
DH $3_{3 \times 3}$	$I_j - I_c + G - 1$	$j$	$2 \times G - 1$	[242]
SH $3_{3 \times 3}$	$I_j + I_c$	$j$	$2 \times G - 1$	[242]

de desplazamiento con orientaciones distintas. En esta tesis hemos adoptado la misma implementación que Haralick *et al.* [88], consistente en promediar las matrices de coocurrencia que se corresponden con desplazamientos entre píxeles adyacentes determinados por orientaciones de  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  y  $135^\circ$ , de modo que el histograma resultante se puede expresar mediante la siguiente ecuación:

$$\mathbf{h}_{\text{HARALICK}}(\mathbf{I}) = \frac{\sum_{j=4}^7 \mathbf{h}_{\text{COOC2},j}(\mathbf{I})}{4} \quad (2.16)$$

donde  $\mathbf{h}_{\text{COOC2},j}(\mathbf{I})$  representa cada uno de los histogramas que contabilizan las coocurrencias de los niveles de gris ( $I_c, I_j$ ).

En el modelo que presentamos se utilizan directamente los elementos en bruto de la matriz de coocurrencia como características de textura [184, 248], si bien es cierto que el enfoque clásico consiste en caracterizar la textura por medio de unos cuantos estadísticos calculados a partir de la matriz, para así alcanzar una mayor reducción de la dimensión del espacio de características, como se verá en la Sección 2.4.2.

Teóricamente es posible considerar relaciones entre las intensidades de un número de píxeles mayor que dos [6]. A pesar de que en esta tesis no hemos implementado este tipo de técnicas debido al elevado coste computacional que conllevan, en la Tabla 2.1 mostramos la formulación de la correspondencia **COOC $3_{3 \times 3}$** , que considera la coocurrencia de tres píxeles, para dejar constancia de que este tipo de descriptores se adaptan perfectamente a nuestro modelo.

El principal inconveniente que se deriva de la extracción de características de textura a partir de las GLCM es la gran cantidad de memoria que demanda para su manipulación y almacenamiento. En numerosas ocasiones se produce una situación paradójica: las matrices de coocurrencia son más pesadas que las propias imágenes a partir de las que se calculan. Además, como consecuencia de su gran dimensión, se puede deducir que son muy sensibles al tamaño de las muestras de textura sobre las que se estiman.

Una posible solución a este inconveniente de las GLCM consiste en estimar la densidad de probabilidad de los valores que toma una función escalar de los niveles de gris de dos píxeles separados una distancia  $\delta \mathbf{r}$ . El ejemplo más antiguo de implementación de esta idea es la técnica conocida como diferencia de nivel de gris o **GLD $3_{3 \times 3}$**  [255], que se fundamenta en el cálculo del histograma de la diferencia en valor absoluto entre los niveles de gris de dos píxeles separados ( $\delta m, \delta n$ ). Posteriormente se propusieron los histogramas de la suma y la diferencia –conocidos en inglés como *Sum Histogram* (SH) y *Difference Histogram* (DH)–, que consisten en calcular los histogramas de sumas y diferencias que se extraen directamente de la imagen fijando una determinada distancia entre píxeles [242]. Concatenando los histogramas **SH $3_{3 \times 3}$**  y **DH $3_{3 \times 3}$**  se obtiene

el histograma *Sum and Difference Histograms* (SDH):

$$\mathbf{h}_{\text{SDH}}(\mathbf{I}) = \mathbf{h}_{\text{SH}}(\mathbf{I}) \otimes \mathbf{h}_{\text{DH}}(\mathbf{I}) \quad (2.17)$$

En la implementación original de Unser [242], la invarianza a rotación se consigue concatenando los cuatro histogramas SDH correspondientes a la suma y diferencia con los píxeles vecinos situados en la horizontal y vertical:

$$\mathbf{h}_{\text{UNSER}}(\mathbf{I}) = \mathbf{h}_{\text{SDH},0}(\mathbf{I}) \otimes \mathbf{h}_{\text{SDH},2}(\mathbf{I}) \otimes \mathbf{h}_{\text{SDH},4}(\mathbf{I}) \otimes \mathbf{h}_{\text{SDH},6}(\mathbf{I}) \quad (2.18)$$

donde  $\mathbf{h}_{\text{SDH},j}$  es una instancia del histograma expresado en la Ecuación 2.17, para la cual las sumas y las diferencias se efectúan entre el píxel central y píxel  $j$  del patrón genérico definido en la Ecuación 2.2.

Conviene aclarar que esta solución difiere de la adoptada en el cálculo de las matrices de coocurrencia, que consistía en promediar los histogramas correspondientes a cuatro direcciones diferentes, tal y como se expresa en la Ecuación 2.16.

### 2.3.2. Umbralización

La característica fundamental de los descriptores de textura basados en umbralización es la sustitución de los niveles de gris de la imagen por valores binarios o ternarios que se obtienen al efectuar distintas comparaciones entre los niveles de gris de los píxeles que conforman el vecindario considerado. A diferencia de los descriptores basados en marginalización, que solamente consideraban un único tipo de relación entre píxeles, los basados en umbralización tienen en cuenta varias relaciones simultáneamente. Todos los descriptores de textura que pertenecen a esta categoría presentan una propiedad destacada: su invarianza frente a transformaciones monotónicas de los niveles de gris.

El origen de esta categoría de descriptores de textura se sitúa a comienzos de la década de 1990 con la aparición de los trabajos de He y Wang sobre las *Texture Units* (TU). En esta técnica las intensidades de los ocho vecinos de un determinado píxel se cuantizan en tres posibles niveles. El valor ternario que se asigna a cada píxel de la periferia del vecindario se establece por comparación con el del píxel central [94, 252], tal como se muestra en la Ecuación 2.14. Como la periferia de una ventana  $3 \times 3$  está formada por ocho píxeles existen  $3^8 = 6561$  posibles patrones de textura, cada uno de los cuales representa un TU diferente. En este modelo la textura se caracteriza mediante el TS, que es un histograma que cuantifica la frecuencia de aparición de las TU en una imagen. En los trabajos desarrollados durante esa primera época se asumía que un píxel de la periferia podía resultar estrictamente mayor, estrictamente menor o igual que el píxel central. En la práctica esta lógica supone la particularización de la Ecuación 2.14 para  $\Delta = 0$ . Es por ello que hemos denominado  $\mathbf{TU}_{3 \times 3}$  a la correspondencia asociada al modelo TU original.

Posteriormente los mismos autores introdujeron una mejora consistente en considerar un intervalo  $\Delta > 0$  en torno al nivel de gris del píxel central [96]. De esta manera se trataba de mitigar la sensibilidad al ruido que presentaba la técnica original así como aumentar el poder de discriminación del TS haciendo que la distribución de las TU sea más uniforme. En la Tabla 2.2 se muestra la expresión matemática de la correspondencia asociada a este modelo, que hemos



Tabla 2.2: Correspondencias basadas en umbralización.

Modelo	$f(\mathbf{S})$	Parám.	$K$	Ref.
BGC1 <sub>3×3</sub>	$\sum_{j=0}^7 \xi(I_j - I_{(j+1) \bmod 8}) \times 2^j - 1$		255	[68]
BGC2 <sub>3×3</sub>	$15 \times \sum_{j=0}^3 \xi(I_{2j} - I_{2(j+1) \bmod 8}) \times 2^j$ $+ \sum_{j=0}^3 \xi(I_{2j+1} - I_{(2j+3) \bmod 8}) \times 2^j - 16$		225	[68]
BGC3 <sub>3×3</sub>	$\sum_{j=0}^7 \xi(I_{3j \bmod 8} - I_{3(j+1) \bmod 8}) \times 2^j - 1$		255	[68]
BTCS <sub>3×3</sub>	$\sum_{j=0}^3 \xi(I_{2j} - \hat{I}) \times 2^j$	$\hat{I}$	16	[187]
CCR <sub>3×3</sub>	$\xi(I_c - \hat{I}) \times 2^8 + \sum_{j=0}^7 \xi(I_j - \hat{I}) \times 2^j$	$\hat{I}$	512	[211]
CLBP_C <sub>3×3</sub>	$\xi(I_c - \bar{I})$	$\bar{I}$	2	[84]
CLBP_M <sub>3×3</sub>	$\sum_{j=0}^7 \xi( I_j - I_c  - \bar{I}) \times 2^j$	$\bar{I}$	256	[84]
CLBP_S <sub>3×3</sub>	$\sum_{j=0}^7 \xi(I_j - I_c) \times 2^j$		256	[84]
CLBP_M/C <sub>3×3</sub>	$256 \times \xi(I_c - \bar{I}) + \sum_{j=0}^7 \xi( I_j - I_c  - \bar{I}) \times 2^j$	$\bar{I}, \bar{I}$	512	[84]
CLBP_S/M <sub>3×3</sub>	$\sum_{j=0}^7 [256 \times \xi(I_j - I_c) + \xi( I_j - I_c  - \bar{I})] \times 2^j$	$\bar{I}$	65536	[84]
CLBP_S/M/C <sub>3×3</sub>	$256^2 \times \xi(I_c - \bar{I}) + 256 \times \sum_{j=0}^7 \xi(I_j - I_c) \times 2^j$ $+ \sum_{j=0}^7 \xi( I_j - I_c  - \bar{I}) \times 2^j$	$\bar{I}, \bar{I}$	131072	[84]
GTUC <sub>3×3</sub>	$\xi( I_7 - I_c  - \Delta) \times 3^7$ $+ \sum_{j=0}^6 \vartheta_{\Delta}(I_j - I_c, I_7 - I_c) \times 3^j$	$\Delta$	4374	[48]
ILBP <sub>3×3</sub>	$\xi(I_c - \bar{S}) \times 2^8 + \sum_{j=0}^7 \xi(I_j - \bar{S}) \times 2^j - 1$		511	[114]
LBP <sub>3×3</sub>	$\sum_{j=0}^7 \xi(I_j - I_c) \times 2^j$		256	[180]
LTPL <sub>3×3</sub>	$\sum_{j=0}^7 \xi(I_c - I_j - \Delta) \times 2^j$	$\Delta$	256	[234]
LTPU <sub>3×3</sub>	$\sum_{j=0}^7 \xi(I_j - I_c - \Delta) \times 2^j$	$\Delta$	256	[234]
MTU16 <sub>3×3</sub>	$\sum_{j=4}^7 \xi(I_c - I_j) \times 2^{j-4}$		16	[259]
MTU81 <sub>3×3</sub>	$\sum_{j=4}^7 \eta_0(I_c - I_j) \times 3^{j-4}$		81	[259]
RTU <sub>3×3</sub>	$\sum_{r=0}^{\alpha_0} (10 - r) + \alpha_1 - 10$		45	[136]
STS <sub>3×3</sub>	$\sum_{j=4}^7 \eta_0(I_j - I_c) \times 3^{j-4}$		81	[259]
STU+ <sub>3×3</sub>	$\sum_{j=0}^3 \eta_{\Delta}(I_{2j} - I_c) \times 3^j$	$\Delta$	81	[157]
STU× <sub>3×3</sub>	$\sum_{j=0}^3 \eta_{\Delta}(I_{2j+1} - I_c) \times 3^j$	$\Delta$	81	[157]
TU0 <sub>3×3</sub>	$\sum_{j=0}^7 \eta_0(I_j - I_c) \times 3^j$		6561	[94]
TUΔ <sub>3×3</sub>	$\sum_{j=0}^7 \eta_{\Delta}(I_j - I_c) \times 3^j$	$\Delta$	6561	[96]

denominado  $\mathbf{TU}\Delta_{3\times 3}$ . Las ventajas de esta solución se ven contrarrestadas por el problema añadido que supone determinar el valor óptimo del parámetro  $\Delta$ .

Sobre la idea original de las TU y el TS se han desarrollado variaciones con la intención común de reducir el tamaño del espacio de características, sin que esta reducción llegue a afectar significativamente a la capacidad de discriminación. La solución más inmediata es la implementación de descriptores de la textura en función solamente de cuatro relaciones y no de ocho, que es el enfoque más implantado, disminuyendo exponencialmente el número de posibles patrones en una ventana  $3 \times 3$ . En este sentido debemos mencionar las *Simplified Texture Units* (STU) [157], con sus dos versiones, la  $\mathbf{STU}+_{3\times 3}$ , que considera únicamente los cuatro píxeles de la periferia  $I_j \in \{I_0, I_2, I_4, I_6\}$  situados en los ejes de simetría vertical y horizontal de la ventana y la  $\mathbf{STU}\times_{3\times 3}$ , que precisamente descarta esos píxeles para realizar cálculos sobre las diagonales  $I_j \in \{I_1, I_3, I_5, I_7\}$ . Debe tenerse en cuenta que en realidad se trata de una técnica híbrida, ya que consiste en la descomposición de las TU en dos descriptores marginales.

Otra variante que se fundamenta en la idea de reducir a cuatro el número de píxeles sobre los que se umbraliza es el *Simplified Texture Spectrum* (STS) [258]. En este caso, que hemos denominado  $\mathbf{STS}_{3\times 3}$  en la Tabla 2.2, se busca eliminar la redundancia que implica la doble comparación que se efectúa sobre un 8-vecindario, donde cada píxel actúa una vez como píxel central y una vez como píxel periférico con respecto a otro. Para ello se utilizan cuatro direcciones consecutivas cualesquiera, generalmente las definidas por los pares de píxeles  $(I_c, I_j)$  donde  $I_j \in \{I_4, I_5, I_6, I_7\}$ . El ahorro en el coste computacional que supone el cálculo de las TU sobre un conjunto de cuatro píxeles en lugar de ocho es evidente y sin embargo la penalización en términos de tasa de acierto es pequeña [259].

No obstante, con anterioridad ya había aparecido una representación comprimida del TS que no necesitaba sacrificar ninguna de las ocho direcciones: las *Reduced Texture Units* (RTU) [136]. Este descriptor cuenta el número de píxeles de la periferia que valen cero y uno después de la umbralización, que se pueden expresar respectivamente como:

$$\alpha_0 = \sum_{j=0}^8 \delta[\eta_0(I_j - I_c)] \quad (2.19)$$

$$\alpha_1 = \sum_{j=0}^8 \delta[\eta_0(I_j - I_c) - 1] \quad (2.20)$$

Los valores anteriores se utilizan para calcular el código  $\mathbf{RTU}_{3\times 3}$  correspondiente a un patrón, como se puede apreciar en la Tabla 2.2.

Recientemente se han presentado los *Local Ternary Patterns* (LTP), un nuevo esquema de codificación que divide los patrones ternarios definidos por las TU en dos canales binarios separados, uno que captura los píxeles cuyo nivel digital es mayor que el umbral y otro en el que sólo se tienen en cuenta los píxeles de valor menor que el umbral [233, 234]. Las correspondencias que asignan códigos a esos patrones binarios superior e inferior se denominan  $\mathbf{LTPU}_{3\times 3}$  y  $\mathbf{LTPL}_{3\times 3}$  respectivamente, y se pueden formalizar según las expresiones que aparecen en la Tabla 2.2. La conversión de un patrón ternario en dos binarios proporciona una considerable reducción del tamaño de los histogramas sin necesidad de descartar ningún píxel de la ventana. El modelo LTP aprovecha la

información de ambos canales mediante una concatenación de los histogramas correspondientes:

$$\mathbf{h}_{\text{LTP}}(\mathbf{I}) = \mathbf{h}_{\text{LTPU}}(\mathbf{I}) \otimes \mathbf{h}_{\text{LTPL}}(\mathbf{I}), \quad (2.21)$$

donde  $\mathbf{h}_{\text{LTPU}}$  se refiere al canal superior y  $\mathbf{h}_{\text{LTPL}}$  al canal inferior.

El modelo LTP puede implementarse sin necesidad de concatenar los histogramas como acabamos de exponer. En efecto, los creadores de este descriptor utilizaron en sus trabajos los dos histogramas por separado y emplearon con cada uno de ellos una medida de similitud distinta, motivados por la especificidad de la aplicación.

Existe una técnica homónima pero diferente de la que acabamos de describir, lo que puede llegar a originar cierta confusión [228]. En realidad esta última no aporta nada más que un cambio de nombre de las muy anteriores TU. Así pues, cuando usemos el término LTP a lo largo de este documento nos estamos refiriendo en todo momento al trabajo desarrollado por Tan y Triggs [233, 234].

El modelo *Gradient Texture Unit Coding* (GTUC) [48] es un refinamiento de las TU que consiste en codificar las diferencias entre el nivel de gris del píxel central y los niveles de gris de dos píxeles de la periferia, en lugar de utilizar un solo píxel de la periferia. Para calcular los códigos de los patrones mediante la correspondencia  $\mathbf{GTUC}_{3 \times 3}$  se debe sustituir la función de umbralización ternaria de una variable de la Ecuación 2.14 por su versión de dos variables:

$$\vartheta_{\Delta}(x, y) = \begin{cases} 0, & \text{si } |x| < \Delta \text{ y } |y| < \Delta \\ 1, & \text{si } |x| < \Delta \text{ y } |y| \geq \Delta \\ & \text{o } |x| \geq \Delta \text{ y } |y| < \Delta \\ 2, & \text{si } |x| \geq \Delta \text{ y } |y| \geq \Delta \end{cases} \quad (2.22)$$

La *Local Binary Patterns* (LBP) constituye uno de los descriptores de textura más ampliamente referenciados y empleados en la actualidad por su simplicidad y por los buenos resultados que proporciona [147]. Su versión más elemental consiste en binarizar las intensidades de los píxeles periféricos empleando como umbral el píxel central. A cada patrón se le asigna un código diferente calculando su producto escalar con un vector de ponderación, cuyos elementos son potencias de dos, como se muestra en la expresión de la correspondencia  $\mathbf{LBP}_{3 \times 3}$ . Como resultado de esta operación, los  $G^9$  posibles patrones en escala de grises se transforman en  $2^8 = 256$  patrones binarios, cada uno de los cuales se corresponde con una clase de equivalencia diferente.

Tradicionalmente se ha atribuido la invención de la LBP al *Machine Vision Group* de la Universidad de Oulu (Finlandia). Esta creencia se basa en la referencia que algunos investigadores de dicho grupo hacen en un informe técnico aparecido en el año 1993 [91] a un artículo, fechado igualmente en 1993, que estaban preparando sobre la LBP. Después de realizar una búsqueda exhaustiva, hemos llegado a la conclusión de que dicho artículo no llegó a publicarse jamás. Los primeros trabajos del grupo de Oulu en los que describen la metodología LBP son dos comunicaciones presentadas en sendos congresos celebrados en el año 1994 [175, 195], pero sus títulos no coinciden con el del pretendido artículo original. En 1996 se publicó el artículo que habitualmente se considera el hito que marca el nacimiento de la LBP [176], cuyo título tampoco coincide con el que

se había anunciado tres años antes. De manera independiente Zabih y Woodfill publicaron en 1994 un trabajo sobre la transformada Census [261], que es un método casi idéntico a la LBP, ya que la única diferencia estriba en el sentido de las desigualdades que aparecen en la función de umbralización binaria que utilizan. La cronología anterior, a pesar de ser ampliamente aceptada, está incompleta pues no refleja el verdadero origen de la LBP, que se remonta al año 1992, con la publicación de un trabajo en el que se particulariza la idea del TS para umbralización binaria [77]. Los propios autores de este artículo reconocen que los inventores de las TU y el TS les sugirieron, a través de una comunicación privada, el desarrollo de esta simplificación. La anterior reconstrucción es una aportación de esta tesis fruto del intenso trabajo de revisión bibliográfica que hemos realizado.

En los descriptores de textura que hemos tratado en este apartado, la umbralización es de carácter local. Sin embargo existen otros en los que la umbralización se efectúa globalmente. Tal es el caso del *Binary Texture Co-occurrence Spectrum* (BTCS) [187], también conocido como método de las 4-tuplas, aparecido casi al mismo tiempo que las TU y el TS. Esta técnica es una particularización de las  $n$ -tuplas binarias utilizadas con anterioridad para diferentes fines, como el reconocimiento de caracteres mediante memorias de acceso aleatorio [33] o el entrenamiento de una red neuronal sencilla, implementada con una memoria de acceso aleatorio, en un esquema genérico de reconocimiento de patrones [7]. Sus autores propusieron dos variantes: una cadena de cuatro píxeles consecutivos alineados en la misma dirección o los cuatro píxeles situados encima, debajo, a la derecha y a la izquierda del píxel central de una ventana  $3 \times 3$ , que es la única que encaja en nuestro modelo unificado. El artículo donde se presenta la BTCS no se especifica el método utilizado para binarizar la imagen. Nosotros hemos empleado el umbral isoentrópico para calcular los códigos de los patrones mediante la correspondencia  $\mathbf{BTCS}_{3 \times 3}$ . Esta umbralización consiste en determinar el nivel de gris que divide la entropía del histograma de una imagen en escala de grises en dos partes iguales [28], se ha aplicado satisfactoriamente a este descriptor de textura con anterioridad

$$\hat{I} = \sum_{g=0}^{G-1} \xi \left[ \frac{1}{2} - e_g(\mathbf{I}) \right] \quad (2.23)$$

$$e_g(\mathbf{I}) = \frac{\sum_{i=0}^g h_i(\mathbf{I}) \log_2 h_i(\mathbf{I})}{\sum_{i=0}^{G-1} h_i(\mathbf{I}) \log_2 h_i(\mathbf{I})} \quad (2.24)$$

donde  $h_i(\mathbf{I})$  es la frecuencia de aparición del nivel de gris  $i$  en la imagen  $\mathbf{I}$ .

Un descriptor muy similar al anterior es la *Coordinated Clusters Representation* (CCR), que consiste en un histograma de 512 componentes que cuantifica la frecuencia de aparición de patrones elementales de textura binaria. Aunque originalmente fue concebida para texturas binarias [139, 140, 141], la CCR pronto se generalizó para texturas en escala de grises [211, 83] e incluso en color [142, 143, 29]. Para ello es necesario binarizar la imagen globalmente, lo que constituye el mayor inconveniente de esta técnica ya que los resultados van a

dependen del método de binarización empleado. En los primeros trabajos sobre la CCR las imágenes se binarizaban mediante el algoritmo *fuzzy c-means* [210]. Al igual que en el BTCS, nosotros hemos implementado la correspondencia  $\mathbf{CCR}_{3 \times 3}$  considerando una binarización isoentrópica, con el fin de evitar los inconvenientes del *fuzzy c-means*, como son la lentitud en su ejecución y la aleatoriedad intrínseca de los resultados. Casi simultáneamente a la aparición del modelo CCR surgieron el *frequency mosaic* [127], una técnica análoga a la versión binaria de la CCR, desarrollada de manera independiente para el análisis de la anisotropía de imágenes digitales, y los *p*-gramas [153], que se probaron sobre imágenes artificiales de rejillas de soporte de combustible nuclear.

Combinando la LBP y la CCR se obtiene la *Improved Local Binary Patterns* (ILBP) [114, 115], en la que todos los niveles de gris de los píxeles de la ventana, incluyendo al central, se binarizan con un umbral  $\bar{S}$  que es el promedio de la intensidad de todos ellos:

$$\bar{S} = \frac{I_c + \sum_{j=0}^8 I_j}{9} \quad (2.25)$$

Por definición, el patrón binario cuyas posiciones son todas iguales a cero es imposible, y por ello existen 511, en lugar de 512, clases de equivalencia definidas por la correspondencia  $\mathbf{ILBP}_{3 \times 3}$ . Existe un modelo casi idéntico a la ILBP que se denomina *Modified Census Transform* (MCT) [72, 134], ya que se desarrolló a partir de la transformada Census.

Recientemente ha aparecido el modelo *Completed Local Binary Patterns* (CLBP) [84], que caracteriza los patrones mediante la intensidad del píxel central y la diferencia de intensidades entre los píxeles periféricos y el píxel central, descompuesta en magnitud y signo. Esto da lugar a tres componentes, denominadas por los autores CLBP\_C, CLBP\_M y CLBP\_S respectivamente.

La intensidad del píxel central se codifica binarizándola con la intensidad media de la imagen:

$$\bar{I} = \frac{\sum_{m=1}^M \sum_{n=1}^N I_{m,n}}{M \times N} \quad (2.26)$$

Por otra parte, la componente de la magnitud se obtiene binarizando el módulo de la diferencia de niveles de gris, empleando como umbral el promedio de las diferencias calculado sobre toda la imagen:

$$\tilde{I} = \frac{\sum_{m=2}^{M-1} \sum_{n=2}^{N-1} \sum_{j=0}^7 |I_j - I_c|}{8 \times (M-2) \times (N-2)} \quad (2.27)$$

La componente del signo se obtiene binarizando la intensidad de los píxeles periféricos usando la intensidad del píxel central como umbral, exactamente del mismo modo que el modelo LBP. Una aportación importante de este trabajo fue la demostración desde un punto de vista teórico de la bondad de la LBP, partiendo de la hipótesis de que la diferencia de intensidad entre dos píxeles sigue una distribución de Laplace [84].

Asimismo, los autores demostraron empíricamente que combinando dos o más componentes individuales, es posible obtener mayor cantidad de información que a partir de una sola. El primero de los esquemas de combinación propuestos consiste en obtener distribuciones conjuntas y se denota mediante el uso de un símbolo /. Por ejemplo, la distribución conjunta del signo y la magnitud se designaría como CLBP\_S/M. Una segunda posibilidad es la concatenación de los histogramas correspondientes, que se denota, como ya hemos visto con anterioridad, mediante el símbolo  $\otimes$ . Por ejemplo, la concatenación de las componentes de signo y magnitud se denotaría de la siguiente forma:

$$\mathbf{h}_{\text{CLBP\_S}\otimes\text{M}}(\mathbf{I}) = \mathbf{h}_{\text{CLBP\_S}}(\mathbf{I}) \otimes \mathbf{h}_{\text{CLBP\_M}}(\mathbf{I}) \quad (2.28)$$

### 2.3.3. Ordenación

Existe un tercer tipo de correspondencia, menos extendido que los dos anteriores que se basa en la ordenación de los niveles de intensidad presentes en los patrones de textura de una imagen. Cada una de las posibles ordenaciones –también denominadas estados– se identifica mediante un código decimal que a su vez representa a la clase de equivalencia correspondiente a dicho estado. La probabilidad de ocurrencia de los patrones equivalentes se estima, al igual que en las otras dos categorías que hemos establecido dentro de nuestro modelo unificado, mediante un histograma.

Las técnicas de ordenación proporcionan dos ventajas muy significativas. En primer lugar, como veremos inmediatamente, la dimensión de estos descriptores es baja, lo que redundará en una menor complejidad computacional y, como consecuencia, suelen ser adecuados para tareas de análisis de texturas en tiempo real. En segundo lugar, estas técnicas suelen presentar una significativa insensibilidad frente a muestras atípicas [103], lo que es síntoma de su robustez.

Los modelos de ordenación o *ranking* se pueden interpretar como una particularización de las  $n$ -tuplas, propuestas inicialmente para el reconocimiento de caracteres [33] o el entrenamiento de una red neuronal sencilla en un esquema genérico de reconocimiento de patrones [7], utilizando en ambos casos memorias de acceso aleatorio. Una  $n$ -tupla es una secuencia formada por los valores de intensidad de  $n$  píxeles situados aleatoriamente dentro de una imagen. En determinadas ocasiones es interesante utilizar píxeles ordenados a lo largo una trayectoria regular, puesto que de este modo se aprovecha el poder de discriminación de ciertas características de la imagen, como ocurre por ejemplo en técnicas de detección de bordes [13, 14].

La aplicación de las  $n$ -tuplas orientadas al análisis de texturas se remonta al modelo BTCS [187], una técnica de umbralización a la que ya nos referimos en la Sección 2.3.2. Posteriormente apareció el *Grey-Level Texture Co-occurrence Spectrum* (GLTCS) [188, 189, 190], un modelo que extiende el BTCS a imágenes en escala de grises, y que es la primera técnica de ordenación propiamente dicha. En el modelo GLTCS se consideran dos 4-tuplas formadas por los píxeles situados a lo largo de las cuatro direcciones principales –N/S y E/O, NE/SO y NO/SE–, descartando el píxel central. Estas dos cadenas de píxeles se ordenan de mayor a menor nivel de gris, lo que se corresponde con un determinado estado o *rank*. Adicionalmente se calcula la varianza para cada dirección. La representación conjunta de los histogramas que se obtienen para cada 4-tupla por separado se puede realizar de tres maneras diferentes. La primera posibilidad

Tabla 2.3: Correspondencias basadas en ordenación.

Modelo	$f(\mathbf{S})$	Parámetros	$K$	Referencias
GLTCS $_{+3 \times 3}$	$\sum_{j=2}^4 \rho_j(\mathbf{X}_+) \times (j-1)!$		$4!=24$	[100]
RANK $_{3 \times 3}$	$\sum_{j=0}^7 [\xi(I_c - I_j) - \delta(I_c - I_j)]$		9	[261]

consiste es promediar o concatenar los histogramas marginales. Esta solución se aplicó en un entorno industrial a la inspección de la superficie de discos magnéticos [98, 99]. La segunda alternativa es una representación direccional, en la que solamente tiene en cuenta la cadena de píxeles correspondiente a la dirección con menor varianza. Finalmente, en los artículos originales de Patel y Stonham acerca de este tema [188, 189, 190] se vislumbra una tercera posibilidad, que es idéntica a la primera que proponíamos salvo por el hecho de que en aquella, la entrada del histograma marginal que se corresponde con la 4-tupla de menor varianza se ve incrementada en dos unidades.

La formalización del GLTCS no resulta trivial. En efecto, los autores del trabajo original se limitaron a definir este modelo mediante una tabla en la que a cada estado se le asigna arbitrariamente un código determinado. Por nuestra parte hemos optado por una caracterización algorítmica en lugar de heurística inspirada en un esquema de cifrado por sustitución [193]. Además de resultar una especificación más elegante y precisa, nuestro enfoque aporta una ventaja adicional, y es que, a diferencia de la definición original, distingue los empates entre los elementos de la 4-tupla.

Sea  $\mathbf{X} = [x_1 \ x_2 \ x_3 \ \dots \ x_n]$  una  $n$ -tupla genérica y  $X_j = \{x_1, x_2, \dots, x_j\}$  el conjunto formado por los  $j$  primeros elementos de  $\mathbf{X}$ . Definamos ahora una función  $\rho_j$  que devuelva el número de elementos de la  $n$ -tupla que se encuentran a la izquierda de  $x_j$  y cuyo valor es mayor o igual que  $x_j$ :

$$\rho_j(\mathbf{X}) = \#\{x \in X_{j-1} | x \geq x_j\}, 2 \leq j \leq n \quad (2.29)$$

De las diferentes modalidades de  $n$ -tuplas propuestas en los trabajos originales de Patel y Stonham, hemos implementado la única formada solamente por las intensidades de los píxeles de una ventana de tamaño  $3 \times 3$ . Hemos denominado **GLTCS** $_{+3 \times 3}$  al descriptor correspondiente, que se calcula utilizando como parámetro de la función  $\rho_j$ , la 4-tupla  $\mathbf{X}_+ = [I_0 \ I_2 \ I_4 \ I_6]$ , donde los elementos de este vector representan la intensidad de los píxeles según la disposición que se muestra en la Ecuación 2.2.

El segundo método perteneciente a esta categoría es la transformada Rank [261], que asigna a un patrón  $3 \times 3$  el número de píxeles cuya intensidad es menor que la del píxel central. La principal ventaja del modelo **RANK** $_{3 \times 3}$ , cuya expresión se recoge en la Tabla 2.3, es su reducida dimensión, ya que el número anterior sólo puede tomar valores comprendidos entre cero y ocho.

## 2.4. Extensiones del modelo

Las correspondencias que hemos analizado en la Sección 2.3 constituyen el núcleo de nuestro modelo teórico, puesto que se ciñen estrictamente a la idea fundamental de esta tesis. Sin embargo, existen otros muchos descriptores que, aun

estando basados en la utilización de histogramas de patrones equivalentes, no se ajustan perfectamente al marco teórico propuesto. El motivo es que estas técnicas introducen algún tipo de modificación o etapa adicional en el esquema definido en la Figura 2.1.

La elaboración de un modelo general que englobe a todos los descriptores basados en la utilización de histogramas de patrones equivalentes es una empresa de gran envergadura que excede ampliamente el alcance de la presente tesis. En cualquier caso, nuestro marco teórico constituye un valioso punto de partida de cara a la consecución de tan ambicioso objetivo. A lo largo de este apartado presentaremos una amplia selección de técnicas estrechamente relacionadas con nuestro modelo teórico pero no incluidas en él, y las agruparemos en una serie de categorías con una doble finalidad. Por una parte, esta clasificación nos permitirá tratarlas de una manera más clara y sistemática y, por otra parte, establece de forma implícita las direcciones en las que puede evolucionar nuestro modelo para convertirse en uno de carácter general.

### 2.4.1. Preprocesamiento

En esta sección incluimos los descriptores que no emplean directamente los valores de intensidad en bruto de la imagen, sino que operan sobre datos derivados a partir de estos. Esta extensión del modelo se representaría en la Figura 2.1 incluyendo un paso previo de preprocesamiento.

Algunas de las técnicas pertenecientes a esta categoría son generalizaciones de técnicas básicas como las matrices de coocurrencia. Un ejemplo son las *Generalized Co-Occurrence Matrices* (GCM), que sustituyen la imagen de textura por otra que indica las posiciones de estructuras geométricas elementales como bordes y líneas [62]. Un caso similar son las *Multidimensional Co-occurrence Matrices* (MDCM), que representan las propiedades y la frecuencia de aparición de determinados atributos como el gradiente [131]. Por otra parte, en ocasiones se realiza un filtrado para extraer los aspectos estadísticos y estructurales de estas propiedades, como ocurre con las *Feature Frequency Matrices* (FFM) [215], o con la *Edge Co-occurrence Matrix* (ECM) [86].

Existen igualmente técnicas que añaden etapas adicionales sobre el TS. Este es el caso de los *prunums* y el *prospectrum* [75], análogos a las TU y al TS respectivamente, pero basados en una primitiva estructural de microtextura extraída mediante una operación de filtrado.

También han surgido variantes destacables a partir de los descriptores basados en las  $n$ -tuplas, como el *Zero Crossing Texture Co-occurrence Spectrum* (ZCTCS), una versión del BTCS donde la única diferencia consiste en filtrar la imagen antes de binarizarla con un filtro laplaciano de la gaussiana, asignando los valores positivos de la señal de salida a un nivel lógico y los negativos al otro [100, 101].

Mención especial merece la LBP debido a la gran cantidad de mejoras y variantes que se han propuesto a lo largo de los últimos años, entre las que destacan los modelos *Joint LBP and variance measure* (LBP/VAR) [180] y *Joint LBP and contrast measure* (LBP/C)[177], que son distribuciones conjuntas de la LBP y el contraste local. En el primer caso el contraste se cuantifica mediante la varianza, y en el segundo restando el promedio de los niveles de gris de los píxeles que se binarizan a uno del promedio de los niveles de gris de los píxeles que se binarizan a cero. Recientemente se ha propuesto reducir la dimensión



de estas distribuciones conjuntas [85]. Este modelo, denominado *LBP Variance* (LBPV), incluye la información del contraste local mediante una proyección integral de la varianza local sobre el histograma de patrones de la LBP, que consiste en sumar el valor de la varianza local en vez de sumar una unidad por cada ocurrencia de un patrón a la componente correspondiente del histograma.

Para finalizar, debemos mencionar el *Local Edge Pattern* (LEP) [260], un modelo análogo a la CCR con la salvedad de que los patrones que se codifican no se extraen a partir de la imagen en escala de grises binarizada, sino que provienen de la salida de un detector de bordes –un filtro de Sobel–.

### 2.4.2. Extracción de características del histograma

Una de las técnicas que se ha utilizado tradicionalmente para reducir la dimensión de un histograma de patrones es la extracción de estadísticos o características a partir del propio histograma. Uno de los ejemplos más conocidos es la extracción de características a partir de las matrices de coocurrencia. En el trabajo original de Haralick *et al.* [88] se proponían 14 características diferentes, aunque en la práctica se suele considerar un número menor. Algunas de las más utilizadas son: la energía, la entropía, el contraste, la correlación o la homogeneidad [192]. Conviene señalar que existen diferencias muy marcadas entre los conjuntos de estadísticos empleados por diferentes autores [46, 80, 107, 150, 151, 173, 186]. Ello es debido a que no existe un criterio universal para seleccionar estos estadísticos y la solución que se suele emplear en la práctica es elegir aquellos que ofrecen los mejores resultados en cada problema particular.

El *Binary Co-Occurrence Matrix* (BCM) es un enfoque similar, consistente en binarizar las matrices de coocurrencia [137, 138], cuantizando sus valores en dos clases: “cero” y “distinto de cero”. La matriz binaria que se obtiene representa la huella de la matriz de coocurrencia. Como medida de similitud de los datos binarios se utilizan el coeficiente de Jaccard [87], que es la proporción de elementos no nulos en ambas matrices que coinciden.

La extracción de características a partir del histograma también se ha adoptado con el TS [253, 95, 50]. Algunos ejemplos significativos son la simetría blanco-negro, que proporciona una medida del grado de simetría entre la parte derecha y la parte izquierda del histograma.

### 2.4.3. Composición de correspondencias

Los descriptores que hemos incluido bajo este epígrafe se caracterizan por aplicar un mapeado adicional  $g$  a los códigos de los patrones equivalentes que proporciona la función  $f$  definida en la Ecuación 2.30. La textura se representará mediante el histograma de los códigos  $k'$  correspondientes a los nuevos patrones equivalentes resultantes de aplicar la composición  $g \circ f$ . Así pues, esta extensión del modelo unificado se puede formalizar adecuadamente del siguiente modo:

$$\begin{array}{ccc} \mathcal{M}_{3 \times 3, G} & \xrightarrow{f} & \mathbb{N} \\ \mathbf{S} & \mapsto & k = f(\mathbf{S}) \end{array} \quad \begin{array}{ccc} & \xrightarrow{g} & \mathbb{N} \\ & \mapsto & k' = g[f(\mathbf{S})] \end{array} \quad (2.30)$$

El objetivo que se persigue con esta operación es una ulterior reducción de la dimensión del espacio de características y, eventualmente, dotar a los histogramas de alguna propiedad beneficiosa, como puede ser la invarianza a rotación,

lo cual se puede conseguir descartando algunas componentes del histograma original, o bien agrupando varias componentes en una sola.

Dentro de las composiciones de correspondencias que buscan estrictamente la reducción de la dimensión del histograma original, no debemos dejar de mencionar los patrones uniformes, una técnica que se suele combinar con la LBP [159]. Los patrones uniformes son aquellos en los que el patrón binario resultante de aplicar una técnica de umbralización presenta como máximo dos transiciones de cero a uno o de uno a cero. Algunos autores, basándose en experimentos realizados sobre diferentes bases de datos de imágenes de textura, afirman que en texturas reales la mayor parte de los patrones son uniformes [180, 152]. La explicación que se daba a esta elevada proporción de patrones uniformes era que dichos patrones representaban ciertas características de la imagen, como bordes, esquinas, puntos, etc. Sin embargo, recientemente se ha demostrado que la alta proporción de patrones uniformes es en realidad una consecuencia directa del propio método, ya que la probabilidad *a priori* de que un patrón sea uniforme es del 55 % aproximadamente [30]. A partir del concepto de uniformidad de un patrón se desarrollaron los patrones simétricos, con los cuales es posible definir otro mapeado adicional a partir del histograma LBP [144], consistente en agrupar en una misma componente los patrones con igual nivel de simetría, definido como el mínimo del número de unos y el número de ceros del patrón LBP.

Los *Dominant Local Binary Patterns* (DLBP) constituyen un enfoque completamente diferente, que consiste en caracterizar la textura mediante las componentes del histograma que representan el 80 % del total de ocurrencias de los patrones LBP [152]. El inconveniente fundamental de esta técnica es que el significado de las componentes del histograma varía de una textura a otra, y por tanto no se puede considerar un método universal.

Dentro de las composiciones de correspondencias debemos incluir dos variantes de la LBP: la *Extended Local Binary Patterns* (ELBP) [264], que asigna cada ocurrencia de un patrón no uniforme a la componente del histograma LBP correspondiente al patrón uniforme cuya estructura es más similar, y la LBP invariante a rotación ( $LBP^{ri}$ ) [180], en el que se sustituye la ventana cuadrada por un vecindario con simetría circular mediante interpolación bilineal y las versiones rotadas de un mismo patrón se consideran equivalentes.

#### 2.4.4. Multiescala

En la Sección 2.1 justificábamos la decisión de limitar el ámbito de nuestro modelo unificado a descriptores basados en ventanas de tamaño  $3 \times 3$  debido principalmente al crecimiento exponencial que se produce en la dimensión de los descriptores, y por lo tanto, en los requisitos computacionales que acarrea su cálculo, a medida que aumenta el tamaño del vecindario considerado. En cualquier caso, no debemos ignorar la existencia de técnicas que utilizan ventanas de tamaño mayor que  $3 \times 3$ . Generalmente estas técnicas consideran simultáneamente varios tamaños de ventana, por lo cual se les suele denominar como técnicas multiescala. Es previsible que en un futuro más o menos inmediato podamos disponer de equipamiento informático de mayor potencia, lo que nos permitirá el análisis generalizado de este tipo de modelos sin las restricciones actuales. Por todo ello, debemos dejar una puerta abierta en nuestro modelo unificado que permita su posterior generalización para incluir cualquier técnica, independientemente del tamaño de ventana en el que se base.

Existen ejemplos de técnicas multiescala dentro de cualquiera de los tres tipos de correspondencias en los que se organiza el modelo unificado. Así, dentro de las técnicas de marginalización, se ha propuesto una generalización de las matrices de coocurrencia que considera parejas de píxeles separados por distancias de hasta cinco píxeles sobre imágenes de satélite [1]. Otra versión de la GLCM multiescala se ha aplicado a la clasificación de imágenes de células del cérvix [39].

Dentro de las técnicas de umbralización cabe destacar un conjunto de versiones de la LBP básica que también utiliza varios tamaños de ventana al mismo tiempo para realizar un análisis multiescala de la textura [180, 158].

Mención aparte merece la técnica conocida como *Surrounding, Alternating, Vertical and Horizontal Contrast* (SAVHC), que también consigue una reducción de la dimensión del TS [112]. En esta técnica se considera una ventana  $5 \times 5$  y el promedio de la intensidad de los dos píxeles situados a lo largo de cada una de las ocho direcciones principales se compara con la intensidad del píxel central. Estos ocho promedios desempeñan el papel de los ocho vecinos en una ventana  $3 \times 3$ , y con ellos se calcula el TS.

El grupo de correspondencias basadas en ordenación contiene igualmente técnicas que utilizan vecindarios de mayor tamaño, como las  $n$ -tuplas orientadas [190], que considera una ventana de tamaño  $5 \times 5$ .

### 2.4.5. Diccionario de patrones

La construcción de un diccionario de patrones consiste en la obtención de un conjunto de patrones representativos de una determinada textura partir de una selección de ejemplos de entrenamiento. La implementación habitual de esta categoría de técnicas se basa en la utilización de algoritmos de conglomeración o *clustering* como el *k-means* [246, 247], redes neuronales como los *Self Organizing Maps* (SOM) [174, 245] o técnicas de cuantización multidimensional como el *Linear Vector Quantization* (LVQ) [178, 179]. Los patrones que forman el diccionario establecen una teselación de Voronoi [66] que particiona el espacio  $\#\mathcal{M}_{3 \times 3, G}$  de manera análoga a las correspondencias que venimos considerando a lo largo de esta tesis. Definamos el diccionario de patrones como:

$$\mathcal{C} = \{\mathbf{C}_j \in \mathcal{M}_{3 \times 3, G} | 0 \leq j \leq K - 1\} \quad (2.31)$$

Siguiendo la notación anterior, a cada patrón  $\mathbf{S}$  presente en una imagen se le asignará la clase de equivalencia  $k$  correspondiente a la entrada del diccionario que se encuentre a una menor distancia:

$$k = \arg \min_j \|\mathbf{S} - \mathbf{C}_j\| \quad (2.32)$$

donde el número total de patrones que componen el diccionario es el número de clases de equivalencia  $K$  definido en la Ecuación 2.7.

Los métodos basados en diccionarios de patrones suelen ofrecer unas elevadas tasas de acierto, aunque generalmente esta precisión se obtiene a costa de una enorme complejidad computacional [247], lo que los hace totalmente inadecuados para aplicaciones en tiempo real. Por otra parte, son métodos que dependen totalmente de los datos de entrada, por lo que resulta preciso determinar diccionarios específicos para cada aplicación concreta. Conviene señalar que estas

técnicas con frecuencia consideran ventanas de tamaño mayor que  $3 \times 3$ , por lo cual también podrían incluirse en la Sección 2.4.4.

### 2.4.6. Lógica borrosa

Muchas de las técnicas de umbralización que hemos mencionado hasta el momento disponen de versiones basadas en lógica borrosa o difusa. El rasgo fundamental que caracteriza a los descriptores basados en umbralización borrosa es la incorporación del concepto de incertidumbre a la comparación que efectúan las técnicas clásicas entre los niveles de gris de los píxeles. Esta incertidumbre se traduce en que el resultado de las funciones de umbralización formalizadas en las Ecuaciones 2.13 y 2.14 sea un conjunto de números reales que cuantifican el grado de pertenencia del argumento de dichas funciones a un determinado intervalo o rango de valores, en lugar de un índice entero que identifica al propio intervalo. Como discutíamos en la Sección 1.1, la propia noción de textura es imprecisa, por lo que resulta razonable pensar que la incorporación del concepto de incertidumbre a la caracterización de la textura aportará algún beneficio.

El enfoque borroso surgió con el propósito de solucionar el problema inherente de sensibilidad al ruido que presentan las técnicas de umbralización clásicas. Este inconveniente es más acusado en los métodos que utilizan dos umbrales, puesto que la pertenencia a uno de los tres intervalos es mucho más infrecuente, lo que provoca que la distribución de los códigos sea muy sesgada.

El abanico de posibilidades que abre la sustitución de la lógica booleana por lógica borrosa es muy amplio, ya que se pueden desarrollar versiones borrosas a partir de cualquier técnica de umbralización. Como muestra, enumeramos a continuación algunos de los descriptores más destacados dentro de esta posible línea de expansión de nuestro modelo unificado: *Fuzzy Texture Spectrum* (FTS) [17, 19], versión borrosa del TS; *Fuzzy Simplified Texture Spectrum* (FSTS) [235], versión borrosa del RTU; *Reduced Fuzzy Texture Spectrum* (RFTS) [18, 82], que consiste en agrupar los patrones del FTS para conseguir un modelo más compacto e invariante a rotación; *Fuzzy Zero Crossing Texture Co-occurrence Spectrum* (FZCTCS) [102], versión borrosa del ZCTCS y *Fuzzy Local Binary Patterns* (FLBP) [4, 106], también denominados *soft histograms*, versión borrosa de la LBP.



## Capítulo 3

# Gradientes Binarios de Contorno

En este capítulo presentamos una nueva familia de descriptores de textura que hemos denominado Gradientes Binarios de Contorno, a la cual nos referiremos a lo largo de esta tesis por las siglas de su traducción al inglés *Binary Gradient Contours* (BGC). Esta técnica se deriva directamente del marco teórico propuesto en el Capítulo 2 y demuestra a la perfección su generalidad y potencialidad. Como veremos en este capítulo, la metodología BGC se fundamenta en el cálculo de un conjunto de ocho gradientes binarios que se obtienen mediante comparaciones entre pares de píxeles situados en la periferia de una ventana de tamaño  $3 \times 3$ . La simplicidad teórica de esta nueva familia de descriptores de textura unida a su reducido coste computacional, nos induce a pensar que su utilización puede resultar efectiva en múltiples situaciones, especialmente en aplicaciones de tiempo real.

### 3.1. Nuevos descriptores de textura

En este apartado definiremos la familia de descriptores BGC e introduciremos su formalización matemática. En virtud de los argumentos expuestos en la Sección 2.1, restringiremos la definición a ventanas de tamaño  $3 \times 3$  píxeles, manteniendo así la coherencia con los descriptores estudiados en el capítulo anterior, aunque se podría generalizar a ventanas de distinto tamaño.

Los operadores  $BGC_{3 \times 3}$  asignan a cada píxel de una imagen una 8-tupla binaria que se obtiene como resultado de aplicar un proceso que consta de dos etapas, que para mayor claridad mostramos en la Figura 3.1(a). En primer lugar se calculan los gradientes entre diferentes parejas de píxeles situadas a lo largo de una trayectoria cerrada alrededor del píxel central del vecindario  $\mathbf{S}$ , definido en la Ecuación 2.2. En segundo lugar estos gradientes se binarizan utilizando el valor 0 como umbral. El criterio para establecer la trayectoria cerrada sobre la cual se calculan los gradientes binarios no es único. Nosotros proponemos tres alternativas que denominaremos bucle simple, bucle doble y bucle triple, a las cuales les corresponderán los operadores  $BGC_{1 \times 3}$ ,  $BGC_{2 \times 3}$  y  $BGC_{3 \times 3}$ , respectivamente. En las Figuras 3.1(b)-(d) se representa esquemáticamente la disposición de las trayectorias para estos tres casos. Asimismo en la Figura 3.1(e)

también se incluye la relación que existe entre los diferentes píxeles que pertenecen al vecindario en el conocido modelo  $LBP_{3 \times 3}$ , lo que permite evidenciar las similitudes y las diferencias que existen entre ambas familias de descriptores.

Teniendo en cuenta la Figura 3.1(a) y la Ecuación 2.13, las correspondientes versiones de los gradientes binarios de contorno pueden expresarse analíticamente de la siguiente manera:

$$\mathbf{g}_1 = \begin{bmatrix} \xi(I_7 - I_0) \\ \xi(I_6 - I_7) \\ \xi(I_5 - I_6) \\ \xi(I_4 - I_5) \\ \xi(I_3 - I_4) \\ \xi(I_2 - I_3) \\ \xi(I_1 - I_2) \\ \xi(I_0 - I_1) \end{bmatrix} \quad (3.1)$$

$$\mathbf{g}_{2\Diamond} = \begin{bmatrix} \xi(I_6 - I_0) \\ \xi(I_4 - I_6) \\ \xi(I_2 - I_4) \\ \xi(I_0 - I_2) \end{bmatrix} \quad (3.2a)$$

$$\mathbf{g}_{2\Box} = \begin{bmatrix} \xi(I_7 - I_1) \\ \xi(I_5 - I_7) \\ \xi(I_3 - I_5) \\ \xi(I_1 - I_3) \end{bmatrix} \quad (3.2b)$$

$$\mathbf{g}_2 = \begin{bmatrix} \mathbf{g}_{2\Diamond} \\ \mathbf{g}_{2\Box} \end{bmatrix} \quad (3.2c)$$

y

$$\mathbf{g}_3 = \begin{bmatrix} \xi(I_5 - I_0) \\ \xi(I_2 - I_5) \\ \xi(I_7 - I_2) \\ \xi(I_4 - I_7) \\ \xi(I_1 - I_4) \\ \xi(I_6 - I_1) \\ \xi(I_3 - I_6) \\ \xi(I_0 - I_3) \end{bmatrix} \quad (3.3)$$




Figura 3.1: (a) Disposición espacial de un patrón  $3 \times 3$  en escala de grises. Representación esquemática de las umbralizaciones correspondientes a los siguientes modelos: (b) BGC de bucle simple, (c) BGC de bucle doble, (d) BGC de bucle triple y (e) LBP.

Es necesario advertir que tanto las 8-tuplas como las 4-tuplas que se recogen en las Ecuaciones 3.1- 3.3 son en realidad funciones de  $\mathbf{S}$ , pero la dependencia explícita con respecto a  $\mathbf{S}$  se ha eliminado para simplificar la notación.

Se puede concluir de manera inmediata que el número de posibles 8-tuplas binarias es  $2^8 = 256$ . Sin embargo, el número de instancias diferentes de las Ecuaciones 3.1, 3.2c y 3.3 se sitúa por debajo de este límite superior puesto que los componentes de estas 8-tuplas no son completamente independientes, al existir restricciones intrínsecas que tienen su origen en el hecho de que esos vectores de gradientes se calculan a lo largo de una trayectoria cerrada. Teniendo en cuenta la desigualdad que aparece en la definición de  $\xi(x)$  es evidente que los ocho componentes de  $\mathbf{g}_1$  no pueden tomar simultáneamente el valor 0. Por lo tanto, el número de gradientes binarios de contorno de bucle simple se reduce a 255. Lo mismo ocurre con  $\mathbf{g}_3$  por lo que existen 255 gradientes binarios de contorno de bucle triple diferentes. El modelo de gradientes binarios de contorno de bucle doble sufre restricciones similares a pesar de que su construcción presenta una diferencia significativa, ya que, como se muestra en la Figura 3.1(c), está constituido por dos trayectorias separadas y no por una única trayectoria cerrada, como sucedía con los otros dos modelos. Para poder explicar esta situación con mayor claridad es conveniente dividir  $\mathbf{g}_2$  en dos mitades: la primera 4-tupla está formada por los cuatro bits más significativos de  $\mathbf{g}_2$  (Ecuación 3.2a) y la segunda 4-tupla por los cuatro bits menos significativos (Ecuación 3.2b), que denotaremos respectivamente como  $\mathbf{g}_{2\blacklozenge}$  y  $\mathbf{g}_{2\blacksquare}$ . De manera inmediata puede deducirse que los cuatro componentes de estas 4-tuplas no pueden tomar el valor cero simultáneamente. De este modo el número de gradientes binarios de contorno diferentes que resulta es  $(2^4 - 1)^2 = 225$ .

De acuerdo con el marco teórico que proponíamos en el Capítulo 2, todos aquellos patrones a los que les corresponde la misma 8-tupla BGC son “equivalentes”, y constituyen una clase de equivalencia dentro del conjunto  $\mathcal{M}_{3 \times 3, G}$  formado por los  $G^9$  posibles patrones  $3 \times 3$  en escala de grises. El código numérico que identifica a las clases de equivalencia asociadas a cada una de las tres versiones de la BGC, o dicho de otro modo, a las distintas instancias de las Ecuaciones 3.1, 3.2c y 3.3, se puede expresar mediante notación matricial del siguiente modo:

$$\text{BGC}_{1 \times 3}(\mathbf{S}) = \mathbf{w}_8^T \mathbf{g}_1 - 1, \quad (3.4)$$

$$\text{BGC}_{2 \times 3}(\mathbf{S}) = 15\mathbf{w}_4^T \mathbf{g}_{2\blacklozenge} + \mathbf{w}_4^T \mathbf{g}_{2\blacksquare} - 16 \quad (3.5)$$

y

$$\text{BGC}_{3 \times 3}(\mathbf{S}) = \mathbf{w}_8^T \mathbf{g}_3 - 1 \quad (3.6)$$

donde el superíndice  $T$  representa “la transpuesta de”, y  $\mathbf{w}_j$  denota al vector de factores de peso definido por:

$$\mathbf{w}_j^T = [ 2^{j-1} \quad 2^{j-2} \quad \dots \quad 2^1 \quad 2^0 ] \quad (3.7)$$

Debe tenerse en cuenta que el vector de pesos se ha elegido de manera arbitraria. Si se hubiera adoptado cualquier otra ordenación simplemente se obtendría como resultado una codificación diferente de los gradientes binarios de contorno. Además, a partir de las Ecuaciones 3.4-3.6 puede comprobarse



fácilmente que las diferentes codificaciones BGC devuelven siempre un índice entero entre 0 y  $K - 1$ .

Hemos utilizado la notación matricial para definir las correspondencias entre patrones de manera compacta, pero es factible reescribir las Ecuaciones 3.4-3.6 en un formato extendido y algorítmico, como mostramos en la Tabla 2.2, en la que también se incluyen las expresiones correspondientes a numerosas técnicas de descripción de la textura que, al igual los miembros de la familia BGC, encuentran cabida dentro del modelo teórico que desarrollábamos en el Capítulo 2.

### 3.2. Eficiencia teórica

Desde el punto de vista clásico de la Teoría de la Información, los distintos conjuntos de clases de equivalencia que se emplean para describir la textura pueden ser considerados como alfabetos de símbolos que se transmiten por un canal discreto ideal (sin ruido) [31]. En este sentido hay que tener en cuenta que la dimensión del espacio de características representa un límite teórico a la cantidad de información que se puede expresar por medio de un modelo de textura cualquiera. Es bien sabido que un alfabeto alcanza la máxima eficiencia cuando los símbolos que lo componen son equiprobables, es decir, cuando la entropía del histograma que se corresponde con la distribución de probabilidad de cada símbolo es máxima [31]. La cuestión que surge a partir de este planteamiento es si en realidad los diferentes modelos de textura alcanzan ese límite teórico y si existe una relación entre la eficiencia de un método de descripción de la textura y su efectividad. Para poder medir ese valor y efectuar un estudio comparativo que nos permita corroborar o refutar esta conjetura definimos la eficiencia  $e_f$  de un modelo de textura del siguiente modo:

$$e_f = \frac{\sum_{k=0}^{K-1} P_f(k) \log_2 P_f(k)}{\log_2 K} \quad (3.8)$$

donde  $P_f(k)$  es la probabilidad *a priori* de la  $k$ -ésima clase de equivalencia del modelo de textura definido por la función o *mapping*  $f$ .

El numerador de la Ecuación 3.8 representa la entropía real o cantidad de información del alfabeto, y el denominador la máxima entropía que se puede alcanzar si se supone equiprobabilidad en los símbolos. En la Tabla 3.1 mostramos las dimensiones así como la máxima entropía alcanzable, de los modelos BGC y LBP.

Para lograr una estimación de la entropía real de los modelos considerados, hemos determinado empíricamente  $P_f(k)$  calculando la proporción de patrones  $3 \times 3$  en escala de grises que pertenecen a cada clase de equivalencia, asumiendo que todos los posibles patrones  $3 \times 3$  en escala de grises son equiprobables. Con este objetivo hemos desarrollado un programa de ordenador que genera todos los posibles patrones  $3 \times 3$  en escala de grises. A continuación es necesario determinar qué código se corresponde con cada patrón, para lo que se toman en consideración las correspondientes expresiones recogidas en la Tabla 2.2. Finalmente se divide el número de patrones que pertenecen a cada clase de equivalencia entre el número total de patrones ( $G^9$ ):

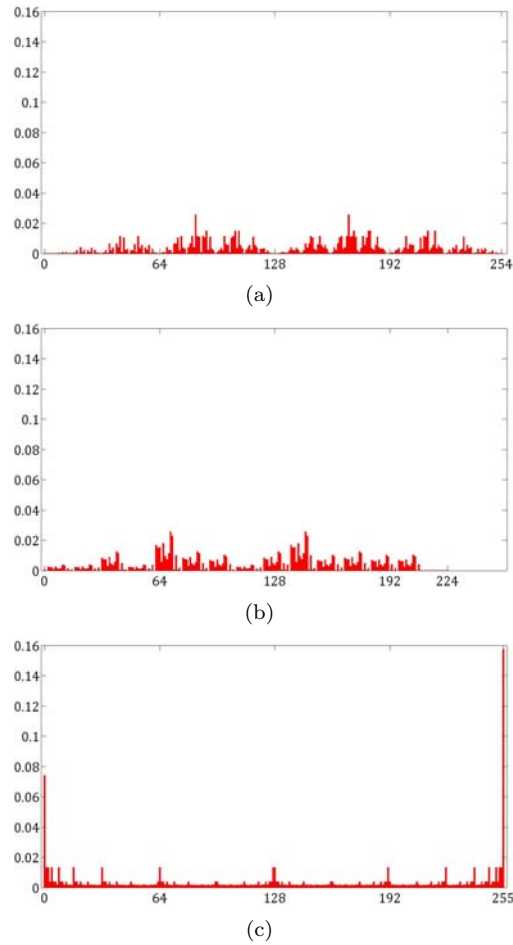


Figura 3.2: Probabilidades *a priori*  $P_f(k)$  de las clases de equivalencia que establecen las siguientes correspondencias: (a) BGC $1_{3 \times 3}$  y BGC $3_{3 \times 3}$ , (b) BGC $2_{3 \times 3}$  y (c) LBP $3_{3 \times 3}$ . Los histogramas se calcularon para  $G = 12$ .

$$P_f(k) = \frac{\#\mathcal{M}_{f,k}}{G^9} \quad (3.9)$$

En la Figura 3.2 se ilustra este proceso al representar en las respectivas gráficas las probabilidades *a priori* de las clases de equivalencia definidas para los modelos BGC y LBP. La eficiencia se calculó aplicando la Ecuación 3.8 a estas probabilidades *a priori*. Únicamente hemos estimado  $P_f(k)$  para valores moderados de  $G$  (número de niveles de cuantización), puesto que a medida que  $G$  se incrementa, el número de posibles patrones  $3 \times 3$  en escala de grises crece exponencialmente lo que repercute de manera decisiva en el tiempo de ejecución. En cualquier caso, el rango de valores de  $G$  que hemos considerado parece suficiente, al llegar a converger la eficiencia para  $G > 7$ , como se muestra en la Figura 3.3.




Figura 3.3: Relación entre la eficiencia teórica y el número de niveles de gris en los modelos BGC y LBP.

### 3.3. Análisis comparativo

Esta sección está dedicada a discutir algunos aspectos importantes de la nueva familia de descriptores de textura que estamos desarrollando a lo largo de este capítulo. Efectuaremos un análisis comparativo de las tres versiones diferentes de la BGC que hemos propuesto. También se estudiarán las diferencias y similitudes entre los modelos LBP y BGC.

#### 3.3.1. BGC frente a LBP

El modelo LBP es una técnica de descripción de la textura muy conocida y ampliamente utilizada. Como consecuencia de la gran atención que esta metodología ha recibido por parte de la comunidad investigadora en temas relacionados con la textura, en la actualidad está disponible una vasta literatura donde se presentan diferentes aplicaciones de las características LBP [147]. Este éxito se apoya en tres razones principales: el modelo LBP es conceptualmente simple, poco exigente desde el punto de vista computacional, por lo que se considera muy adecuado para el procesamiento en tiempo real, y muy preciso en la discriminación de texturas. Son muy numerosas las publicaciones en las que se pueden encontrar descripciones detalladas del modelo LBP, como por ejemplo en [161]. El operador de textura  $LBP_{3 \times 3}$  se define normalmente partiendo del concepto de umbralización local: los valores en escala de grises de la periferia de una ventana  $3 \times 3$  se convierten en un conjunto de valores binarios utilizando el nivel de gris del píxel central como umbral. La LBP asigna a cada píxel de la imagen un código que habitualmente se define mediante la fórmula que se muestra en la Tabla 2.2.

En esta tesis proponemos abordar el modelo LBP desde una perspectiva diferente. Consideramos que, en realidad, la LBP puede interpretarse como una correspondencia o mapeo del espacio de patrones en escala de grises al espacio de 8-tuplas binarias y, consiguientemente, este modelo de textura cabe perfec-

tamente en el marco conceptual general descrito en el Capítulo 2. Para destacar aún más si cabe la conveniencia del marco teórico basado en correspondencias entre patrones para describir el modelo LBP, es adecuado reformular la LBP empleando la notación matricial, como hacíamos en la Sección 3.1 en el caso de la BGC. Con este objetivo definimos la siguiente 8-tupla:

$$\mathbf{g}_* = \begin{bmatrix} \xi(I_7 - I_c) \\ \xi(I_6 - I_c) \\ \xi(I_5 - I_c) \\ \xi(I_4 - I_c) \\ \xi(I_3 - I_c) \\ \xi(I_2 - I_c) \\ \xi(I_1 - I_c) \\ \xi(I_0 - I_c) \end{bmatrix} \quad (3.10)$$

Debe tenerse en cuenta que se ha eliminado la dependencia de  $\mathbf{S}$  con el propósito de simplificar la expresión, siguiendo un procedimiento análogo al que se explicó en el caso de las Ecuaciones 3.1-3.3. La anterior ecuación representa los ocho gradientes calculados con respecto al píxel central en las orientaciones determinadas por los ocho píxeles vecinos de éste, los cuales se binarizan utilizando el valor 0 como umbral. Existen  $2^8 = 256$  instancias diferentes de la Ecuación 3.10, ya que en este caso los gradientes de intensidad no se calculan a lo largo de una trayectoria cerrada y por lo tanto cualquier componente de la 8-tupla puede tomar los valores 0 y 1, independientemente de los valores que tomen las demás componentes.

Los patrones en escala de grises a los que se les asigna en el modelo LBP la misma 8-tupla que aparece definida en la Ecuación 3.10 pertenecen al mismo grupo de patrones equivalentes. La frecuencia con que se repiten los diferentes grupos de patrones equivalentes se recoge en un histograma formado por 256 barras para representar la textura presente en una imagen. Cada grupo de patrones se codifica para asignarle una etiqueta que facilite su manejo, utilizando para ello la notación matricial definida con anterioridad:

$$\text{LBP}_{3 \times 3}(\mathbf{S}) = \mathbf{w}_8^T \mathbf{g}_* \quad (3.11)$$

Al contrario de lo que ocurre con las Ecuaciones 3.4-3.6, debe advertirse que en este caso no es necesario incluir un término sustractivo en la fórmula, pues el producto escalar de  $\mathbf{w}_8^T$  y  $\mathbf{g}_*$  puede valer 0.

Llegados a este punto podríamos plantearnos qué interés puede suscitar la utilización de las características BGC si como hemos comentado, la LBP está íntimamente relacionada con ellas y además es muy efectiva en la discriminación de texturas. Nuestra hipótesis de partida se fundamenta en considerar que la eventual mejora que pudiera introducir la nueva familia de descriptores que proponemos en términos de precisión, se explicaría por el hecho de que, como veremos a continuación, su eficiencia teórica es ligeramente superior con respecto a la ya clásica LBP.

### 3.3.2. Versiones de la BGC

A pesar de que conceptualmente son idénticos, los tres miembros de la familia de características de textura BGC que hemos desarrollado presentan algunas

Tabla 3.1: Resumen de características de los modelos de textura considerados: dimensión del espacio de características ( $K$ ), máxima entropía alcanzable expresada en bits ( $\log_2 K$ ), eficiencia teórica ( $e_f$ ) calculada para  $G = 12$  niveles de cuantización, separación entre píxeles ( $\|\delta\mathbf{r}\|$ ), y orientaciones del gradiente ( $\theta$ ).

Modelo	$K$	$\log_2 K$	$e_f$	$\ \delta\mathbf{r}\ $	$\theta$
BGC $1_{3\times 3}$	255	7.9944	0.8996	1	$0, \pm\frac{\pi}{2}, \pi$
BGC $2_{3\times 3}$	225	7.8138	0.8983	$\sqrt{2}, 2$	$0, \pm\frac{\pi}{4}, \pm\frac{\pi}{2}, \pm\frac{3\pi}{4}, \pi$
BGC $3_{3\times 3}$	255	7.9944	0.8996	$\sqrt{5}$	$\pm\arctan\frac{1}{2}, \pi \pm\arctan\frac{1}{2},$ $\pm\arctan 2, \pi \pm\arctan 2$
LBP $3_{3\times 3}$	256	8	0.8533	$1, \sqrt{2}$	$0, \pm\frac{\pi}{4}, \pm\frac{\pi}{2}, \pm\frac{3\pi}{4}, \pi$

diferencias que merecen un comentario detallado. Además, resultará fructífero analizar las similitudes y las divergencias entre los descriptores de textura BGC y LBP.

Una propiedad importante tanto del modelo BGC como de la LBP es la invarianza con respecto a la intensidad ya que estos descriptores no se ven afectados por transformaciones monotónas de los valores en escala de grises de los píxeles de la imagen, como puede deducirse inmediatamente de las definiciones.

Todos los modelos considerados se basan en 8-tuplas binarias. No obstante, la dimensión de sus correspondientes espacios de características no es la misma. El histograma de la LBP $3_{3\times 3}$  tiene  $2^8 = 256$  barras, pero los histogramas de la BGC no alcanzan este límite superior al verse los componentes de las 8-tuplas condicionados por las restricciones intrínsecas que se discutían en la Sección 3.1. Las dimensiones de estos espacios de características se resumen en la Tabla 3.1. El hecho de que los modelos tengan diferentes dimensiones justifica que las entropías máximas que se pueden alcanzar sean también diferentes.

Basándonos en el análisis de la eficiencia teórica que detallábamos en la Sección 3.2 formularemos algunas observaciones interesantes. En primer lugar, la Figura 3.2 revela claramente que las probabilidades *a priori* de las clases de equivalencia definidas a través de los correspondientes *mappings* son bastante diferentes. El modelo LBP $3_{3\times 3}$  presenta dos picos significativos en ambos extremos del histograma, mientras que en los histogramas de la BGC las frecuencias de ocurrencia están distribuidas de una manera más uniforme. Concretamente, el 23.14 % de los posibles patrones  $3 \times 3$  en escala de grises se concentran en sólo dos de los subconjuntos en los que se particiona el conjunto  $\mathcal{M}_{3\times 3,12}$  al utilizar la correspondencia que crea el modelo LBP $3_{3\times 3}$ . El restante 76.86 % de patrones se distribuye en cambio entre los otros 254 subconjuntos de patrones. En cambio, los modelos BGC producen una partición más equilibrada de  $\mathcal{M}_{3\times 3,12}$  al contener el subconjunto más poblado en estos casos tan sólo el 2.57 % de los posibles patrones en escala de grises. En segundo lugar, es importante advertir que las probabilidades *a priori* de las clases de equivalencia inducidas por los modelos BGC $1_{3\times 3}$  y BGC $3_{3\times 3}$  son idénticas. Esto está motivado, por una parte, por el hecho de que ambos gradientes binarios se calculan a lo largo de una única trayectoria cerrada en vez de manejar dos trayectorias cerradas separadas, como sucede con el modelo BGC $2_{3\times 3}$  (véase la Figura 3.1), y por otra parte, por la hipótesis de que las intensidades de los píxeles son estadísticamen-

te independientes. Finalmente, la Figura 3.3 permite concluir que los *mappings* BGC contienen una mayor cantidad de información textural que la  $LBP_{3 \times 3}$  y, por lo tanto esto podría justificar la eventual mejoría que podrían introducir las características BGC en términos de eficiencia en la discriminación de textura con respecto a la LBP. Esta hipótesis se ve reforzada por los resultados experimentales que se incluyen en el Capítulo 4.

La representación esquemática que se muestra en la Figura 3.1 sugiere que la escala y la orientación del gradiente varían de un modelo a otro. Así, el intervalo de muestreo  $\|\delta\mathbf{r}\| = \sqrt{\delta m^2 + \delta n^2}$  es único en los operadores  $BGC1_{3 \times 3}$  y  $BGC3_{3 \times 3}$  (véase la Tabla 3.1) mientras que en los operadores  $BGC2_{3 \times 3}$  y  $LBP_{3 \times 3}$  los valores en escala de grises de los píxeles se comparan por parejas en dos escalas diferentes. En lo referente a la orientación, en el caso del modelo  $BGC1_{3 \times 3}$  los gradientes se calculan para cuatro ángulos diferentes, utilizando ocho ángulos diferentes en los demás modelos. Consecuentemente el modelo  $BGC1_{3 \times 3}$  abarca únicamente cuatro tipos de interacciones entre parejas de píxeles, en concreto los gradientes entre píxeles que se encuentran separados por una distancia unitaria en cuatro orientaciones diferentes, mientras que el resto de modelos incorporan una mayor variedad de interacciones entre parejas de píxeles.

Como último comentario nos gustaría destacar que el operador  $LBP_{3 \times 3}$  tiene en cuenta a todos los píxeles del vecindario  $3 \times 3$ , cosa que no ocurre con los modelos BGC, que sólo consideran los ocho bits de la periferia. A pesar de que parezca extraño que se descarte el píxel central, es una solución empleada y documentada con anterioridad en técnicas similares de descripción de la textura. El motivo por el que se prescinde del píxel central se basa en el hecho de que las texturas se consideran con frecuencia realizaciones de un campo aleatorio de Markov, y dentro de este marco, la probabilidad del píxel central depende solamente de su vecindario [192]. En el *neighbourhood classifier* [247], la textura se modela como la frecuencia de aparición de los textones que forman parte de un diccionario. Los textones son los centroides que resultan de agregar y agrupar pequeños recortes de la imagen original. Estos recortes de la imagen están formados por las intensidades en bruto de los píxeles de un vecindario cuadrado en el que el píxel central se descarta, de manera análoga al modelo BGC. Otro modelo de textura que excluye el píxel central es el *Texture Co-occurrence Spectrum* (TCS) [189], en el que cuatro máscaras orientadas a 0, 45, 90 y 135 grados alrededor de cada píxel se usan para extraer información de textura en función de la ocurrencia conjunta de los valores de cuatro píxeles para una dirección dada. Para reducir la dimensión de las características se utilizó la técnica conocida como codificación del *ranking*.



## Capítulo 4

# Experimentos

A lo largo de más de cuatro décadas de investigación en el ámbito del análisis de texturas se han propuesto numerosos descriptores, cuyo desarrollo ha seguido un enfoque eminentemente aplicativo. Este planteamiento ha provocado un rápido e innegable avance en la materia, pero adolece de dos limitaciones importantes: la práctica inexistencia de fundamentos teóricos que justifiquen el mejor o peor comportamiento de un descriptor de textura frente a otros y la falta de generalidad de las conclusiones extraídas.

Así, salvo contadas excepciones, cuando se proponía un nuevo descriptor de textura, su validación solía consistir en medir su tasa de acierto, definiendo normalmente un experimento de clasificación o segmentación y utilizando como dato de entrada un determinado conjunto de imágenes. El objetivo de estos trabajos era demostrar empíricamente que la tasa de acierto del nuevo descriptor era superior a la de los existentes. Por consiguiente, la investigación se ha orientado principalmente a la mejora de los resultados, sin que existiera un interés claro por estudiar los fundamentos teóricos que permitan determinar las causas por las que un descriptor de textura es mejor o peor que otros.

Asimismo, como ya se indicó en la Sección 1.4.2, se han publicado diferentes estudios comparativos, pero son parciales y poco representativos porque consideran un reducido conjunto de descriptores y/o bases de datos. Así pues, resulta imposible inferir de manera concluyente a partir de ellos cuál es el descriptor más adecuado para una aplicación determinada.

En esta tesis hemos realizado una comparación muy extensa que abarca a todos aquellos descriptores de textura que conforman el núcleo del modelo unificado que hemos propuesto. Nuestra evaluación comparativa se basa en una serie de experimentos de clasificación de imágenes en los que hemos considerado todos estos descriptores. Estos experimentos se han validado sobre 10 bases de datos diferentes. Además se ha estudiado el comportamiento de los descriptores de textura de nuestro interés en una aplicación real: la detección automática de invernaderos a partir de imágenes de satélite.

Comenzaremos este capítulo describiendo brevemente las características de las colecciones de imágenes que hemos empleado en nuestro trabajo experimental. A continuación explicaremos la metodología en la que nos hemos basado, para finalizar con una discusión acerca de los resultados cuantitativos que hemos obtenido.



## 4.1. Datos utilizados

Los datos que hemos utilizado en nuestros experimentos son de dos tipos. Por una parte disponemos de 10 bases de datos formadas por imágenes de textura estacionaria. Nueve de estas colecciones han sido desarrolladas por grupos de investigación interesados en el análisis de texturas y son de dominio público en Internet. La décima es una colección de imágenes elaborada por miembros de nuestro grupo de investigación que se ha utilizado con anterioridad en aplicaciones de clasificación y recuperación automática de baldosas de granito. Por otra parte hemos utilizado imágenes de satélite de alta resolución. En esta sección comentaremos las características más significativas de todas ellas.

### 4.1.1. Texturas genéricas

#### Brodatz

El álbum de Brodatz [41] es una de las primeras y más conocidas colecciones de imágenes empleadas en trabajos de investigación relacionados con la visión por computador y el procesamiento de imágenes. Dicho álbum alcanzó gran popularidad a partir de la década de 1970, convirtiéndose en cierto modo en un estándar *de facto* para la evaluación de algoritmos de análisis de texturas [194], dado que en aquel tiempo era la única colección de imágenes que contaba con un número considerable de texturas fotografiadas bajo condiciones de iluminación controladas.

A pesar de su popularidad, las texturas de Brodatz presentan una serie de inconvenientes. En primer lugar son imágenes publicadas en papel, por lo que resulta imprescindible su digitalización. Este proceso es dependiente del dispositivo de adquisición utilizado y supone una fuente de variabilidad en los resultados. Además, las imágenes de la publicación original están protegidas por derechos de autor.

Son varias las colecciones de imágenes de Brodatz que podemos encontrar en Internet. En esta tesis hemos optado por utilizar la base de datos de imágenes proporcionada por el *Signal & Image Processing Institute (USC-SIPI)* de la Universidad del Sur de California [244]. La principal característica de esta base de datos es que las imágenes que contiene no están escaneadas a partir de las páginas del libro original de Brodatz, sino de fotografías en escala de grises que fueron adquiridas directamente al autor. Estas imágenes pueden diferir en algunos casos de las que se recogen en el libro. Las texturas de Brodatz incluidas en la base de datos USC-SIPI suman un total de 13 imágenes en escala de grises y en formato *Tagged Image File Format (TIFF)* con una resolución de  $1024 \times 1024$  píxeles. La Figura A.1 muestra un mosaico de dichas imágenes. Para disponer de varios ejemplos de cada clase hemos dividido todas las imágenes en 16 partes iguales, lo que resulta en 208 ejemplos disponibles para el entrenamiento y la validación.

#### Jerry Wu

Esta base de datos fue creada por Jerry Wu, investigador del *Texture Lab* en la Universidad Heriot-Watt (Escocia), para su tesis doctoral sobre clasificación de texturas tridimensionales invariante a rotación [113]. Está formada por 2100 imágenes de superficies tridimensionales con una resolución de  $512 \times 512$  píxeles.

Dichas imágenes pertenecen a 39 clases diferentes, la mayoría de las cuales – concretamente 36 de 39 – están representadas por 56 imágenes de la misma textura que se corresponden con siete ángulos de rotación y ocho de inclinación diferentes. La excepción a este paradigma son las clases etiquetadas como «bp6», «di1» y «wp1», que sólo están representadas por 28 muestras, puesto que para estas clases las capturas se efectuaron a cuatro ángulos de inclinación. Tanto en este caso excepcional como en el más general, el eje óptico de la cámara forma un ángulo de  $45^\circ$  con respecto a la dirección de iluminación.

Para realizar nuestro experimento de clasificación hemos seleccionado aquellas imágenes para las cuales los ángulos de rotación y de inclinación son  $0^\circ$  (Figura A.2). Tal y como se indica en la Tabla 4.1, hemos dividido las 39 imágenes seleccionadas en cuatro partes iguales de  $256 \times 256$  píxeles, con lo cual el número de ejemplos asciende a 156.

## KTH-TIPS

La base de datos KTH-TIPS –KTH es la abreviatura de la universidad sueca *Kungliga Tekniska Högskolan*, en castellano Real Instituto de Tecnología, y TIPS es el acrónimo de *Textures under varying Illumination, Pose and Scale*– fue diseñada con la intención de proporcionar una colección de imágenes que permitiera un estudio sistemático acerca de la importancia que ejerce la distancia existente entre la cámara y el objeto sobre la clasificación de materiales [132]. En cierto sentido se puede considerar que KTH-TIPS es un subconjunto de la base de datos *Columbia-Utrecht Reflectance and Texture Database* (CURET) [57] porque está formada por imágenes de 10 materiales seleccionados entre los 61 que aparecen en CURET.

KTH-TIPS está formada por imágenes fotografiadas bajo diversas condiciones de iluminación, posición y distancia con respecto a la cámara. Concretamente las fotografías se tomaron a nueve escalas equiespaciadas logarítmicamente a lo largo de dos octavas, para cada una de las cuales se combinaron tres ángulos de rotación con respecto a la cámara y tres direcciones de iluminación. Esto significa que KTH-TIPS contiene 81 imágenes por clase, es decir, 810 imágenes en toda la base de datos.

Tanto en las imágenes de CURET como las de KTH-TIPS la textura no abarca toda la imagen, por lo cual debe recortarse un borde exterior para eliminar la escena de fondo. Ante esta situación nos hemos decantado por trabajar con las imágenes de KTH-TIPS, ya que han sido recortadas manualmente por sus desarrolladores. De este modo, por una parte evitamos tener que manipular la base de datos original y, por otra, conseguimos que los resultados obtenidos sean comparables con los que puedan derivar de trabajos de investigación análogos, pues no dependen de ninguna decisión particular que pudiéramos haber tomado al respecto.

Nosotros hemos seleccionado las imágenes tomadas a la escala #5, que corresponde a una distancia de 28cm entre la cámara y el objeto, y con ángulos de iluminación y observación  $0^\circ$  (Figura A.3). Estas imágenes una vez recortadas tienen una resolución de  $200 \times 200$  píxeles. A su vez las hemos dividido en cuatro partes de  $100 \times 100$  píxeles para disponer de cuatro ejemplos por clase.

### KTH-TIPS2b

Durante los años posteriores a la aparición de KTH-TIPS, que data de 2004, sus creadores ampliaron este trabajo y presentaron KTH-TIPS2 en 2006 [132]. Esta extensión de la base de datos original contiene cuatro muestras de 11 materiales diferentes, lo que hace un total de 44 clases. Como ocurría con KTH-TIPS, estos 11 materiales están igualmente presentes en CURET, lo que abre la puerta a la realización de experimentos en los que se combinen ambas bases de datos. En esta tesis hemos renunciado a esta posibilidad por los mismo motivos que exponíamos al hablar de KTH-TIPS. Por otra parte, seis de esos 11 materiales ya aparecían en KTH-TIPS.

Se han definido dos versiones de esta base de datos: KTH-TIPS2-a y KTH-TIPS2-b. KTH-TIPS2-b es análoga a KTH-TIPS en el sentido de que también contiene imágenes de superficies tomadas a nueve escalas equiespaciadas logarítmicamente a lo largo de dos octavas, con tres posibles ángulos de rotación con respecto a la cámara. Sin embargo, en la elaboración de la nueva versión se utilizaron cuatro direcciones de iluminación en vez de las tres que se habían empleado con anterioridad, lo que resulta en un total de  $12 \times 9 = 108$  imágenes por clase. Por su parte, KTH-TIPS2-a contiene la misma cantidad de imágenes que KTH-TIPS2-b para 40 de las 44 clases, pero sólo 72 imágenes en las cuatro clases restantes.

Debido a la limitación anterior y dado que KTH-TIPS2-b es la versión más reciente, hemos elegido esta última para nuestro trabajo experimental. Al igual que hicimos con KTH-TIPS, hemos seleccionado las imágenes tomadas a la escala #5, que corresponde a una distancia de 28cm entre la cámara y el objeto, y con ángulos de iluminación y observación  $0^\circ$  (Figura A.4). Sobre las imágenes originales de  $200 \times 200$  píxeles se han obtenido 4 ejemplos no solapados de  $100 \times 100$  píxeles por clase, lo que hace que el número de ejemplos disponibles de esta base de datos ascienda a 176.

### Outex

Outex constituye un completo y útil banco de pruebas para la evaluación empírica de algoritmos de clasificación, segmentación y recuperación de texturas [183]. Esta herramienta se desarrolló en el *Machine Vision Group* (MVG) de la Universidad de Oulu (Finlandia) con el fin de dar respuesta a un problema persistente durante más de tres décadas de investigación activa en el ámbito del análisis de texturas: la inexistencia de una metodología común que permita evaluar la eficacia de los diferentes descriptores de textura que se han propuesto a lo largo de este período [181]. Antes de la aparición de Outex, cualquier trabajo experimental conducente a la validación de una nueva técnica de análisis de texturas implicaba una serie de decisiones, acerca de las imágenes utilizadas, su partición en un conjunto de entrenamiento y un conjunto de prueba, o incluso el criterio empleado en la cuantificación de los resultados, por poner algunos ejemplos. Todos estos factores tienen una notable influencia en el resultado final del experimento. Debido a ello la utilización de imágenes procedentes de la misma base de datos no garantizaba la obtención de resultados experimentales comparables, ya que estos dependían de cada configuración particular.

La base de datos Outex consta actualmente de 320 texturas en escala de grises y en color, tanto microtexturas como macrottexturas, que se corresponden

con 29 materiales diferentes. Estas imágenes se organizan en bancos de prueba o *test suites* utilizables en tres tipos de experimentos: clasificación, segmentación –supervisada y no supervisada– o recuperación de imágenes. En lo que se refiere a la clasificación, la gran ventaja de Outex reside en el hecho de que cada *test suite* particular fija todas las variables que intervienen en un experimento: el conjunto de imágenes, la división es éste en un subconjunto de entrenamiento y otro de validación, y el método de cálculo de la medida de bondad. Este planteamiento del *test suite* como una caja negra en la que el dato de entrada es el descriptor de textura bajo estudio y la salida es su medida de bondad –tasa de acierto y coste computacional– es el único que permite extraer conclusiones significativas a partir de las comparaciones entre descriptores.

En el experimento de clasificación que hemos diseñado para comparar los descriptores de textura objeto de nuestro análisis hemos utilizado tres *test suites* de Outex diferentes: Outex TC\_00000, Outex TC\_00001 y Outex\_00013. En los dos primeros casos los conjuntos de entrenamiento y validación de un problema de clasificación de texturas particular se extraen de la misma colección, formada por 24 imágenes en escala de grises –véase Figuras A.6 y A.7–, que se reparten aleatoriamente en dos mitades para obtener una estimación insesgada de su tasa de acierto. Para aumentar la estabilidad de la estimación de la tasa de acierto la partición aleatoria se repite 100 veces. La única diferencia entre Outex TC\_00000 y Outex TC\_00001 es el número de subimágenes no solapadas en que se dividen las 24 imágenes originales. Outex TC\_00000 utiliza muestras de  $128 \times 128$  píxeles, mientras que las de Outex TC\_00001 son de  $64 \times 64$  píxeles, extrayéndose un total de 480 y 2112 muestras respectivamente, es decir 20 muestras por clase para Outex TC\_00000 y 88 para Outex TC\_00001. En cuanto a Outex TC\_00013, el conjunto de texturas está formado por 68 imágenes en color que se muestran en la Figura A.8. El tamaño de las muestras es de  $128 \times 128$  píxeles, a razón de 20 muestras por clase, lo que hace un total de 1360 muestras. La partición de las muestras en un conjunto de entrenamiento y un conjunto de validación es análoga a la descrita para los *test suites* Outex TC\_00000 y Outex TC\_00001, pero a diferencia de los dos casos anteriores, no existen problemas predefinidos para Outex TC\_00013, por lo que esta tarea ha sido definida según nuestro propio criterio.

### UIUCtex

La base de datos UIUCTex<sup>1</sup> [146] –acrónimo de *University of Illinois at Urbana-Champaign Texture*– consta de 1000 imágenes, distribuidas en 25 clases a razón de 40 muestras por clase, con una resolución de  $640 \times 480$  píxeles. En la Figura A.9 se recoge un mosaico formado por una muestra de cada una las 25 clases. UIUCTex incluye fotografías de superficies cuya textura se debe principalmente a variaciones de albedo –predominante en las clases «madera» y «mármol»–, relieve –clases «gravilla» y «piel»–, así como a una mezcla de ambos fenómenos –clases «alfombra» y «ladrillo»–. Las imágenes que componen la base de datos UIUCTex presentan importantes variaciones de escala, perspectiva y orientación. Estos factores, unidos a la falta de control sobre las condiciones de iluminación durante el proceso de adquisición de imágenes, suponen una

<sup>1</sup>UIUCTex estuvo disponible al público en el sitio [http://www-cvr.ai.uiuc.edu/ponce\\_grp](http://www-cvr.ai.uiuc.edu/ponce_grp). Desgraciadamente, en la fecha en la que se escribió esta memoria de tesis, dicha URL era inaccesible y parece que los creadores de la base de datos han abandonado su mantenimiento.

Tabla 4.1: Resumen de características de las bases de datos empleadas en los experimentos de clasificación de imágenes de textura estacionaria.

Base de datos	Clases	Ejemplos por clase	Ejemplos	Resolución ejemplos (px)	Formato	¿Problem. predef.?
Brodatz	13	16	208	256 × 256	Color	No
Jerry Wu	39	4	156	256 × 256	B/N	No
KTH-TIPS	10	4	40	100 × 100	B/N	No
KTH-TIPS2b	44	4	176	100 × 100	B/N	No
Mondial Marmi	12	64	768	136 × 136	Color	No
OuTeX TC_00000	24	20	480	128 × 128	B/N	Sí
OuTeX TC_00001	24	88	2112	64 × 64	B/N	Sí
OuTeX TC_00013	68	20	1360	128 × 128	Color	No
UIUCtex	25	40	1000	640 × 480	Color	No
VisTex	167	4	668	256 × 256	Color	No

considerable dificultad añadida con respecto a otras bases de datos.

### VisTex

Los investigadores del *Media Lab*, dependiente del *Massachusetts Institute of Technology* (MIT), desarrollaron *Vision Texture* (VisTex), que se concibió como una base de datos de dominio público, como alternativa al álbum de Brodatz que, como mencionábamos anteriormente, no es de uso libre para fines de investigación [251]. A diferencia de otras bases de datos, las imágenes de VisTex no han sido fotografiadas en condiciones de laboratorio, sino que pretenden reflejar las condiciones que se dan en el mundo real. Como característica novedosa de VisTex podemos destacar la inclusión de texturas que no estaban presentes en las colecciones de texturas tradicionales.

VisTex se divide en cuatro colecciones: «Texturas de Referencia», «Escenas de Textura», «Texturas de Video» y «Órbitas de Video». En nuestro trabajo hemos considerado únicamente la primera colección, dado que las otras tres o se encuentran en construcción, o bien están formadas por imágenes heterogéneas que contienen varias texturas. Todas las imágenes de la colección «Texturas de Referencia» están disponibles en dos resoluciones:  $512 \times 512$  y  $128 \times 128$  píxeles. Nosotros hemos utilizado el tamaño mayor, y hemos dividido las 167 imágenes que componen la colección (Figura A.10), en cuatro partes de  $256 \times 256$  píxeles sin solapamiento, por lo que el número de ejemplos con los que contamos es de 668.

#### 4.1.2. Granitos

La evaluación del experimento de clasificación de texturas se completa con la inclusión de una base de datos de imágenes de granito, que hemos denominado Mondial Marmi. Dicha colección, que ya fue utilizada en anteriores trabajos del grupo de investigación [69], está formada por fotografías de tablas de granito que pertenecen a 12 variedades comerciales cuyos nombres enumeramos a continuación: *Aquamarina*, *Azul Capixaba*, *Azul Platino*, *Bianco Cristal*, *Bianco Sardo*, *Giallo Napoletano*, *Giallo Ornamentale*, *Giallo Santa Cecilia*, *Giallo Veneziano*, *Rosa Beta*, *Rosa Porriño A*, *Rosa Porriño B*. Las baldosas de granito fueron suministradas por la empresa manufacturera del sector de la piedra natural *Mondial Marmi SpA* (Perugia, Italia).

El sistema de adquisición utilizado para capturar estas imágenes de granitos consistió en un anillo de lámparas *Light-Emitting Diode* (LED) montado en la base de una cúpula opaca hemiesférica de 46.5cm de diámetro, cuya pared interna está recubierta por un material que se aproxima a un difusor lambertiano ideal. Los rayos luminosos incidentes en cualquier punto de la piedra a fotografiar se distribuyen por toda la superficie como consecuencia de las múltiples reflexiones en el material difusor, lo que proporciona a la baldosa de granito una iluminación uniforme. Las imágenes de textura en color se fotografiaron utilizando una cámara digital de consumo fija (Samsung S850), que se sujetó firmemente a la cúpula para mantener constante la distancia de la cámara a la baldosa. Esta configuración se adoptó para evitar el problema de las reflexiones especulares en baldosas de granito pulidas.

Mondial Marmi consta de cuatro imágenes en color por cada clase, lo que hace un total de 48 imágenes (Figura A.5). Con el fin de que esta base de datos resultara de utilidad para la evaluación de descriptores de textura invariantes a rotación, se agregaron imágenes rotadas por *hardware* y por *software*. Las imágenes rotadas por *hardware* se capturaron en los ángulos que el sistema de montaje proporcionaba: 0°, 5°, 10°, 15°, 30°, 45°, 60°, 75° y 90°. Esto hace un total de 432 imágenes –48 para cada ángulo de rotación–. Las imágenes rotadas por *software* se obtuvieron por interpolación bilineal e interpolación bicúbica a partir de aquellas cuyo ángulo de rotación era 0°. Con el fin de disponer de una mayor número de ejemplos por clase, cada una de estas imágenes se ha dividido en 16 subimágenes cuadradas. Finalmente, debemos señalar que las imágenes que forman esta colección solamente representan la parte central de las capturas originales. De este modo se elimina la escena de fondo que aparece cuando se fotografía una baldosa de granito rotada, y se descartan igualmente las esquinas, que están ocultas en algunas posiciones. Así, si  $W$  y  $T$  son respectivamente el ancho y el alto de la imagen original –en este caso  $1024 \times 768$  píxeles–, el área que se debe conservar es un cuadro centrado de dimensión  $\min(W, T)/\sqrt{2}$ . Esto explica que las dimensiones de las imágenes de la base de datos Mondial Marmi sean  $544 \times 544$  píxeles.

### 4.1.3. Imágenes de satélite

Con el fin de validar experimentalmente las técnicas ensayadas en una aplicación concreta como es la detección automática de invernaderos a partir de imágenes de satélite, hemos utilizado una porción de una imagen georreferenciada de la zona del Campo de Níjar, tomada en el año 2004 por el satélite QuickBird, que mostramos en la Figura 4.1. Las coordenadas UTM (zona 30, WGS-84) de los vértices SW y NE de la porción estudiada son (572739.7, 4086639.5) y (579165.1, 4089884.3), respectivamente, y abarca una extensión de 2084.95ha (6425.5m  $\times$  3244.8m). Los experimentos se han realizado empleando la imagen pancromática cuantizada con 8 bits y ortorrectificada con una resolución de 0,6m/píxel.

Sobre la imagen original hemos delineado manualmente un conjunto de 1498 polígonos, de los cuales 1280 corresponden a la clase *greenhouse* y 218 corresponden a la clase *nogreenhouse*, que en la Figura 4.2 se representan en color verde y rojo, respectivamente. Cada uno de estos polígonos desempeñará el mismo papel que desempeñaba una imagen en los experimentos de clasificación de texturas estacionarias. Para ello a cada polígono se le asigna un identificador y se calcula




Figura 4.1: Región considerada en la imagen del satélite QuickBird.

el histograma de patrones equivalentes en el interior de la región de la imagen original correspondiente al recorte poligonal.

## 4.2. Metodología experimental

En esta sección describiremos el procedimiento que hemos seguido para evaluar cuantitativamente las prestaciones de los diferentes descriptores de textura que hemos considerado en esta tesis. El proceso que nos disponemos a detallar es común para todos los tipos de datos que describíamos en la Sección 4.1.

En primer lugar se determinan los códigos de los patrones elementales de textura correspondientes a cada píxel de las imágenes empleando las expresiones de las Tablas 2.1, 2.2 y 2.3 y de las Ecuaciones 2.16, 2.18, 2.21 y 2.28. A continuación se obtiene un histograma para cada imagen a partir de dichos códigos. En el caso de la imagen de satélite se calcula un histograma diferente para cada polígono. El conjunto formado por todos los histogramas se denomina  $\mathcal{H}$ . Estos histogramas son los vectores de características que representan a cada uno de los ejemplos, ya sean estos imágenes de textura estacionaria o recortes poligonales de una imagen de satélite. Llamaremos  $\mathbf{h}$  al histograma asociado a un ejemplo genérico y designaremos por  $clase(\mathbf{h})$  a la etiqueta de clase del ejemplo correspondiente.

A continuación se divide aleatoriamente  $\mathcal{H}$  en dos subconjuntos disjuntos:  $\mathcal{A}_i$  para el aprendizaje y  $\mathcal{V}_i$  para la validación:

$$\mathcal{H} = \mathcal{A}_i \cup \mathcal{V}_i \quad \forall i \quad (4.1)$$




Figura 4.2: Detalle de la región considerada y polígonos empleados para el *ground truth*. La clase *greenhouse* se representa en verde y la *nogreenhouse* en rojo.

$$\mathcal{A}_i \cap \mathcal{V}_i = \emptyset \quad \forall i \quad (4.2)$$

Existen diferentes criterios para determinar los subconjuntos de entrenamiento y validación. Nosotros hemos optado por subdividir aleatoriamente  $\mathcal{H}$  de modo que  $\mathcal{A}_i$  y  $\mathcal{V}_i$  tengan el mismo número de vectores (*split-half*) y conserven exactamente la misma proporción de vectores de cada clase que en el conjunto total (*stratified sampling*) [40, 227]:

$$\#\mathcal{A}_i = \#\mathcal{V}_i = \frac{\#\mathcal{H}}{2} \quad \forall i \quad (4.3)$$

$$\begin{aligned} p_c &= \frac{\#\{\mathbf{h} \in \mathcal{H} | \text{clase}(\mathbf{h}) = c\}}{\#\mathcal{H}} \\ &= \frac{\#\{\mathbf{a} \in \mathcal{A}_i | \text{clase}(\mathbf{a}) = c\}}{\#\mathcal{A}_i} \\ &= \frac{\#\{\mathbf{v} \in \mathcal{V}_i | \text{clase}(\mathbf{v}) = c\}}{\#\mathcal{V}_i} \end{aligned} \quad (4.4)$$

donde  $c$  es un índice que identifica a una clase y cumple que  $1 \leq c \leq C$ , siendo  $C$  el número total de clases.

Para cada uno de los vectores  $\mathbf{v}_\beta$  del conjunto de validación se determina su vecino más cercano, es decir, el vector del conjunto de aprendizaje que se encuentra a la menor distancia en el espacio de características:

$$\mathbf{a}_\beta = \arg \min_{\mathbf{a} \in \mathcal{A}_i} \|\mathbf{v}_\beta - \mathbf{a}\| \quad (4.5)$$

Para cuantificar la similitud entre histogramas hemos empleado la norma  $L_1$  de Minkowski, también conocida como distancia de Manhattan o *cityblock* [207]. En caso de que el ejemplo a clasificar y su vecino más cercano tengan la misma etiqueta de clase, se considera que la clasificación es correcta, y en caso contrario incorrecta. Cuando se han clasificado todos los ejemplos del conjunto de validación se calcula la tasa de acierto dividiendo el número de clasificaciones correctas por el número total de clasificaciones. Para formalizar este índice resulta conveniente definir la función  $1NN$  que, dado un vector del conjunto de



validación y su vecino más cercano en el conjunto de aprendizaje, devuelve un uno o un cero en caso de que ambos pertenezcan a la misma o a distinta clase respectivamente:

$$1NN(\mathbf{v}_\beta, \mathbf{a}_\beta) = \begin{cases} 1 & : \text{clase}(\mathbf{v}_\beta) = \text{clase}(\mathbf{a}_\beta) \\ 0 & : \text{clase}(\mathbf{v}_\beta) \neq \text{clase}(\mathbf{a}_\beta) \end{cases} \quad (4.6)$$

Los clasificadores basados en la regla del vecino más cercano son muy populares debido a la sencillez de su implementación y a los buenos resultados que proporcionan. Sin embargo, presentan una importante limitación cuando el vecino más cercano no es único, es decir, cuando hay dos o más patrones de entrenamiento pertenecientes a clases diferentes que se encuentran ubicados a la distancia mínima con respecto al patrón a clasificar. Nosotros hemos resuelto estos casos de empate empleando el clasificador de mínima distancia, que asigna la etiqueta del centroide de la clase más cercana [66]. En aquellos casos excepcionales en los que el clasificador de mínima distancia tampoco sea capaz de decidir, nuestra rutina de clasificación, asigna la etiqueta de clase *unclassifiable* para evitar cualquier tipo de aleatoriedad.

A partir de esta función que acabamos de definir resulta sencillo definir la tasa de acierto correspondiente a una división particular del conjunto de ejemplos  $\mathcal{H}$  en los subconjuntos de aprendizaje  $\mathcal{A}_i$  y validación  $\mathcal{V}_i$ :

$$t_i = \frac{\sum_{\beta=1}^{\#\mathcal{V}_i} 1NN(\mathbf{v}_\beta, \mathbf{a}_\beta)}{\#\mathcal{V}_i} : \mathbf{v}_\beta \in \mathcal{V}_i \quad (4.7)$$

A fin de tener una estimación más estable de la tasa de acierto la división aleatoria se repite 100 veces –cada una de estas instancias es lo que en Outex se denomina problema– y la tasa de acierto global se calcula como el promedio de las 100 tasas de acierto individuales:

$$t_\mu = \frac{\sum_{i=1}^{100} t_i}{100} \quad (4.8)$$

A fin de tener una medida de la dispersión de la tasa de acierto obtenida en los diferentes problemas, hemos calculado la desviación típica insesgada:

$$t_\sigma = \frac{\sum_{i=1}^{100} (t_i - t_\mu)^2}{99} \quad (4.9)$$

Con el fin de poder establecer comparaciones entre los distintos descriptores, todo el proceso expuesto en los párrafos precedentes se repite para cada uno de los modelos de textura considerados.

### 4.3. Resultados obtenidos

En esta sección vamos a comentar los resultados que hemos obtenido al aplicar la metodología que acabamos de exponer en la Sección 4.2 a los dos tipos de

experimentos de clasificación supervisada que hemos desarrollado. En el primer caso hemos utilizado imágenes de textura estacionaria, y en el segundo, objetos obtenidos por segmentación manual de una imagen de satélite.

Hemos codificado todos los descriptores de textura incluidos en el núcleo de nuestro modelo unificado, a los que hacíamos referencia en la Sección 2.3, en el lenguaje de programación de MATLAB. En el Apéndice B se muestra el código fuente de la función que calcula el histograma de patrones equivalentes  $3 \times 3$  para las diferentes correspondencias que hemos implementado. Llegados a este punto debemos indicar que, a pesar de que hemos podido probar la mayor parte de dichas técnicas, algunos descriptores han quedado fuera del trabajo experimental, dado que su elevada dimensión requiere una cantidad memoria que excede la capacidad de los ordenadores a los que hemos tenido acceso durante el desarrollo de esta tesis, de los cuales detallamos sus principales características a continuación:

- Ordenador 1: Procesador Intel Core 2 Quad Q8200 2.33GHz; 4GB de RAM; Sistema Operativo Windows 7.
- Ordenador 2: Procesador Intel Core 2 Quad Q6600 2.40GHz; 4GB de RAM; Sistema Operativo Windows XP Profesional.


#### 4.3.1. Clasificación de imágenes

En el experimento de clasificación de imágenes se han utilizado las nueve colecciones de texturas estacionarias genéricas que describíamos en la Sección 4.1.1. Asimismo se ha incluido la base de datos de elaboración propia formada por imágenes de baldosas de granito a la que nos referíamos en la Sección 4.1.2.

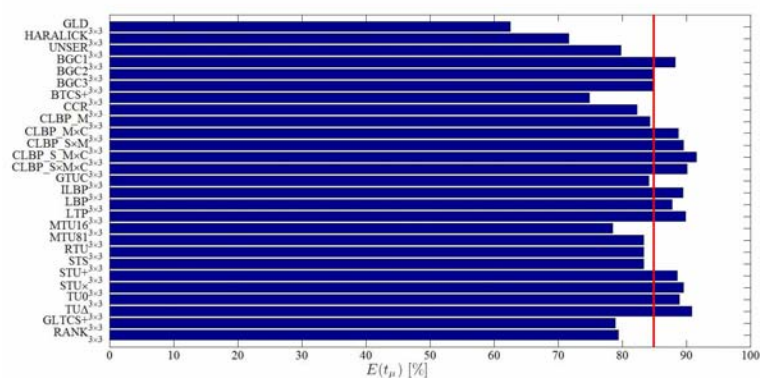
El número total de descriptores que hemos probado en este experimento asciende a un total de 27, teniendo en cuenta que los métodos que dependen de un parámetro se contabilizan como uno solo y que los modelos  $CLBP_{S \otimes M \otimes C_{3 \times 3}}$  y  $COOC_{3 \times 3}$  no se han podido utilizar en la práctica, debido a sus elevados requisitos computacionales. Los resultados numéricos detallados del experimento se encuentran en el Apéndice A y se distribuyen en 30 tablas, de modo que a cada base de datos le corresponden tres tablas, una por cada tipo de correspondencia: marginalización, umbralización y ordenación.

El propósito fundamental de este trabajo experimental es presentar un estudio comparativo lo más amplio posible de las prestaciones de los descriptores de textura bajo análisis. A simple vista resulta complicado determinar cuál es el mejor descriptor de los 27 que hemos ensayado debido al gran volumen de datos generado. Con frecuencia se ha empleado la tasa de acierto como índice de bondad para comparar cuantitativamente diferentes descriptores de textura. Sin embargo, la valoración que aporta este índice por sí solo es parcial, puesto que no contempla aspectos muy relevantes como el tiempo de cómputo, que es un factor crucial en aplicaciones en tiempo real.


Con el fin de ofrecer una visión de conjunto que nos ayude a extraer conclusiones significativas, en la Figura 4.3 se muestran tres gráficas que resumen los resultados detallados del Apéndice A. Estas gráficas representan la dimensión de los 27 descriptores considerados –Figura 4.3(a)–, la tasa de acierto que han alcanzado esos descriptores promediada para las 10 bases de datos que hemos utilizado –Figura 4.3(b)– y su tiempo de cómputo relativo promediado –Figura 4.3(c)–, cuyo cálculo se detalla en el Apéndice A.



(a)



(b)



(c)

Figura 4.3: Resumen de los resultados del experimento de clasificación de imágenes de textura estacionaria: (a) dimensión de los descriptores, (b) tasa de acierto promediada y (c) tiempo de cómputo relativo promediado.

Con el fin de determinar las técnicas que presentan un mejor comportamiento combinado, hemos definido un criterio de selección basado en relacionar la dimensión de cada descriptor, así como su tasa de acierto y su tiempo de cómputo relativo, con las medianas de estos valores promediados para cada descriptor sobre las 10 bases de datos consideradas. Si definimos estas medianas como  $K_{\text{med}}$ ,  $t_{\text{med}}$  y  $T_{\text{med}}$  respectivamente, el criterio de selección consiste en el cumplimiento simultáneo de las tres condiciones siguientes:

$$K \leq K_{\text{med}} \quad (4.10a)$$

$$E(t_{\mu}) \geq t_{\text{med}} \quad (4.10b)$$

$$E(T) \leq T_{\text{med}} \quad (4.10c)$$

donde  $E(\cdot)$  denota el valor medio del parámetro correspondiente.

Para facilitar la interpretación de este criterio se han superpuesto sendas líneas verticales de color rojo a las Figuras 4.3(a), 4.3(b) y 4.3(c) que cortan a los ejes de abscisas correspondientes en  $K_{\text{med}}$ ,  $t_{\text{med}}$  y  $T_{\text{med}}$  respectivamente. Partiendo de esta premisa, los mejores descriptores son aquellos que se ubican a la izquierda de las líneas rojas de las Figuras 4.3(a) y 4.3(c), y a la derecha de la línea roja de la Figura 4.3(b).

Con el fin de determinar si las diferencias existentes entre las tasas de acierto de los diferentes descriptores son significativas, es preciso realizar un contraste de hipótesis estadísticas [225]. A tal efecto hemos implementado una prueba basada en la técnica de los rangos con signo de Wilcoxon [170] sobre todas las combinaciones de parejas que se pueden formar con los 27 modelos de textura considerados en este experimento. Sean  $t$  y  $t'$  dos vectores de 100 componentes que contienen las tasas de acierto que se obtienen mediante dos descriptores de textura distintos sobre 100 problemas, que es, como se indicó en la Sección 4.2, el número de veces que se repite el experimento de clasificación sobre cada base de datos. La prueba de los rangos con signo de Wilcoxon contrasta la hipótesis nula de que las componentes del vector  $t - t'$  provienen de una distribución continua, simétrica y con mediana igual a cero, frente a la alternativa de que la mediana de la distribución no sea igual a cero. Así pues, mediante este test podemos comprobar para cada pareja de descriptores si existen diferencias estadísticamente significativas entre las distribuciones que siguen sus tasas de acierto. El contraste de hipótesis se ha realizado para un nivel de confianza  $\alpha = 5\%$ , por lo que en todos los casos en los que se supere el umbral de 0,05 podemos afirmar que la victoria de un descriptor sobre aquel al que se enfrenta es relevante.

En la Tabla 4.2 se muestran los resultados del contraste de hipótesis que hemos realizado. Se trata de una matriz  $27 \times 28$  donde el valor que aparece en la  $i$ -ésima fila y en la  $j$ -ésima columna, siendo  $1 \leq i, j \leq 27$ , representa al número de bases de datos para las cuales la tasa de acierto media obtenida por el modelo  $i$ -ésimo es significativamente mayor que la tasa de acierto media obtenida por el modelo  $j$ -ésimo. La última columna de la matriz es la suma de la 27 columnas precedentes y recoge el número total de victorias de cada uno de los descriptores en la prueba de Wilcoxon. La suma de un elemento cualquiera de la matriz y su simétrico con respecto a la diagonal principal es por definición menor o igual que el número de bases de datos considerado. En la Figura 4.4 se muestra, en orden decreciente, el número de victorias obtenidas en el test de Wilcoxon por

Tabla 4.2: Resultados del test de Wilkoxon.

Características	GLD <sub>3×3</sub>	HARALICK <sub>3×3</sub>	UNSER <sub>3×3</sub>	BGC1 <sub>3×3</sub>	BGC2 <sub>3×3</sub>	BGC3 <sub>3×3</sub>	BTCS+ <sub>3×3</sub>	CCR <sub>3×3</sub>	CLBP_M <sub>3×3</sub>	CLBP_M/C <sub>3×3</sub>	CLBP_S/M <sub>3×3</sub>	CLBP_S⊗M/C <sub>3×3</sub>	CLBP_S/M/C <sub>3×3</sub>	GTUC <sub>3×3</sub>	ILBP <sub>3×3</sub>	LBP <sub>3×3</sub>	LTP <sub>3×3</sub>	MTU16 <sub>3×3</sub>	MTU81 <sub>3×3</sub>	RTU <sub>3×3</sub>	STS <sub>3×3</sub>	STU+ <sub>3×3</sub>	STU× <sub>3×3</sub>	TU0 <sub>3×3</sub>	TUΔ <sub>3×3</sub>	GLTCS+ <sub>3×3</sub>	RANK <sub>3×3</sub>	Nº Victorias	
GLD <sub>3×3</sub>	0	7	0	1	0	3	3	0	3	3	0	3	3	0	3	3	0	6	4	4	0	0	0	0	0	0	0	0	3
HARALICK <sub>3×3</sub>	9	9	0	3	5	5	6	3	5	5	2	1	2	3	2	3	1	6	5	5	4	3	3	3	2	5	4	4	80
UNSER <sub>3×3</sub>	10	7	7	7	9	9	10	9	10	10	4	2	5	9	3	3	3	10	10	9	5	5	3	3	2	10	5	5	112
BGC1 <sub>3×3</sub>	10	6	5	0	0	0	9	6	7	4	1	0	0	7	1	0	0	10	8	7	10	0	0	2	0	10	7	7	173
BGC2 <sub>3×3</sub>	10	6	5	0	0	0	10	6	7	1	1	0	0	10	0	0	0	10	8	8	8	0	0	2	0	10	7	7	109
BGC3 <sub>3×3</sub>	9	4	4	0	0	3	10	6	6	0	0	1	0	6	1	1	0	3	0	1	0	0	0	1	0	10	7	7	116
BTCS+ <sub>3×3</sub>	10	7	5	1	0	0	0	0	6	0	0	0	0	1	0	0	0	0	4	4	4	0	0	0	0	10	3	27	80
CCR <sub>3×3</sub>	10	6	5	0	0	3	10	0	0	0	2	0	0	3	0	0	0	8	4	5	4	0	0	0	0	7	6	6	80
CLBP_M <sub>3×3</sub>	10	6	5	0	2	2	10	6	0	0	2	0	0	6	0	0	0	10	4	4	4	5	0	0	0	10	10	7	160
CLBP_M/C <sub>3×3</sub>	10	6	6	3	7	7	10	9	10	10	4	0	0	10	4	4	1	10	10	9	10	5	1	4	0	10	10	8	179
CLBP_S/M <sub>3×3</sub>	10	8	8	3	9	9	10	8	8	8	0	3	0	8	4	5	4	10	9	9	9	5	5	5	3	3	10	8	179
CLBP_S/M/C <sub>3×3</sub>	10	9	8	6	9	9	9	9	10	10	5	2	0	10	3	4	6	10	10	10	10	0	0	0	6	6	10	8	215
CLBP_S⊗M/C <sub>3×3</sub>	10	8	7	6	9	9	9	8	8	2	0	2	0	0	0	0	0	8	9	9	9	0	0	0	5	5	9	8	172
CLBP_S/M/C <sub>3×3</sub>	10	7	5	0	3	3	9	6	2	0	1	0	2	0	0	0	0	8	4	6	4	0	0	0	0	8	6	6	84
GTUC <sub>3×3</sub>	10	7	7	7	7	7	10	9	10	10	5	2	0	0	0	0	0	10	10	9	10	4	4	2	2	10	7	7	186
ILBP <sub>3×3</sub>	10	7	7	7	7	7	10	9	10	10	3	3	3	10	0	0	0	10	10	9	10	8	5	4	2	10	8	8	155
LBP <sub>3×3</sub>	10	7	7	7	7	7	10	9	10	10	8	5	1	10	4	8	0	10	10	9	10	0	0	0	0	10	7	7	197
LTP <sub>3×3</sub>	10	7	7	7	7	7	10	9	10	10	5	1	0	10	4	8	0	10	10	9	10	8	5	4	2	10	8	8	155
MTU16 <sub>3×3</sub>	9	4	4	3	0	0	9	2	0	0	0	0	0	0	0	0	0	10	0	0	0	1	0	0	0	10	4	4	37
MTU81 <sub>3×3</sub>	10	6	6	5	1	2	10	4	3	3	0	0	0	10	4	8	0	10	10	3	0	0	0	0	0	10	7	7	81
RTU <sub>3×3</sub>	10	6	6	5	0	0	10	9	10	10	0	0	0	10	0	0	0	10	10	0	0	0	0	0	0	10	8	8	77
STS <sub>3×3</sub>	10	6	6	5	0	0	10	9	10	10	0	0	0	10	0	0	0	10	10	0	0	0	0	0	0	10	8	8	79
STU+ <sub>3×3</sub>	10	6	6	5	0	0	10	9	10	10	0	0	0	10	0	0	0	10	10	0	0	0	0	0	0	10	8	8	157
STU× <sub>3×3</sub>	10	8	7	7	7	7	10	9	10	10	4	0	0	10	3	6	3	10	10	9	10	7	0	1	0	10	8	8	185
TU0 <sub>3×3</sub>	10	7	7	7	7	7	10	9	10	10	4	3	1	10	1	5	0	10	10	9	10	5	2	0	0	10	8	8	166
TUΔ <sub>3×3</sub>	10	10	8	7	7	7	10	9	10	10	4	3	1	10	1	4	5	10	10	10	10	8	7	0	0	10	8	8	211
GLTCS+ <sub>3×3</sub>	9	5	4	0	0	3	7	3	0	0	0	0	0	10	0	0	0	5	0	2	0	0	0	0	0	10	0	5	41
RANK <sub>3×3</sub>	10	6	5	0	0	2	8	3	0	0	1	0	0	3	0	0	0	4	0	0	0	0	0	0	0	4	0	0	62

los mejores descriptores, es decir, aquellos que cumplen simultáneamente las tres condiciones que recogíamos en las Ecuaciones 4.10a-4.10c. Cabe destacar que dos de estos cinco mejores modelos pertenecen a la familia BGC.




Figura 4.4: Selección de los mejores descriptores ordenados de mayor a menor número de victorias en la prueba de Wilcoxon.

No quisiéramos finalizar esta sección sin incluir una breve discusión en relación a los resultados contenidos en el Apéndice A. Si nos centramos en exclusiva en la precisión de los descriptores, se puede comprobar inmediatamente que en general se manifiesta una notable dispersión. Aun así, existen bases de datos en las que muchos descriptores alcanzan tasas de acierto del 100 %, lo que produce un efecto de saturación que enmascara y dificulta la interpretación de los resultados obtenidos en el test de Wilcoxon. Si el dato que nos interesa es el tiempo de cómputo, la mayor parte de las técnicas consideradas se encuentran dentro del mismo orden de magnitud, aunque se producen excepciones, como algunos miembros de la familia CLBP o el modelo HARALICK $_{3 \times 3}$ , cuya excesiva dimensión provoca que su coste computacional sea inasumible en la mayor parte de las situaciones. El caso de la CLBP es especialmente significativo, puesto que alguna de sus versiones obtiene tasas de acierto de las más elevadas, pero resulta totalmente inadecuada porque incluso puede provocar un agotamiento de la memoria durante la ejecución. Por otra parte, debemos tener en cuenta que algunos de los descriptores incluidos en este experimento dependen de algún parámetro. Así, en el modelo GLD se manifiesta una acusada dependencia de la tasa de acierto con respecto al píxel del patrón que se tiene en cuenta para el cálculo de la diferencia. En los métodos en los que es preciso especificar un rango  $\Delta$ , como GTUC, LTP,  $STU^+$ ,  $STU^x$  y  $TU\Delta$ , también se aprecian variaciones importantes. De hecho, el método que encabeza la selección que mostramos en la Figura 4.4 es el  $STU^x$ . El número de victorias que se recoge en ese gráfico se refiere en exclusiva al valor  $\Delta$  con el que se obtienen las mayores tasas de acierto, que puede superar hasta en 20 puntos porcentuales al peor resultado. Por este motivo, resultaría de gran utilidad disponer de un criterio que permita determinar el valor óptimo de los parámetros, sin necesidad de realizar una búsqueda exhaustiva, como efectivamente hemos tenido que llevar a cabo en esta ocasión, y caracterizar la forma en la que la elección de uno u otro valor para un determinado parámetro afecta a la tasa de acierto.

### 4.3.2. Clasificación de objetos

El experimento de clasificación de imágenes al que nos acabamos de referir en la Sección 4.3.1 constituye un valioso banco de pruebas para evaluar y extraer conclusiones acerca del comportamiento de los descriptores de textura que han suscitado el interés de esta tesis. No obstante, hemos considerado conveniente realizar un segundo tipo de pruebas para comprobar si es posible extrapolar los resultados obtenidos en el experimento ‘de laboratorio’ a una aplicación práctica.

Es esta sección estudiaremos la viabilidad de introducir descriptores de textura en un problema de análisis de imágenes basado en objetos presente en el ámbito de la teledetección. En concreto, nos hemos ocupado de la detección automática de invernaderos en una imagen de satélite que describíamos en la Sección 4.1.3, una aplicación en la que se pueden distinguir claramente dos etapas. En primer lugar es preciso fragmentar la imagen en diferentes objetos para, seguidamente, proceder a clasificarlos para detectar cuáles de estos objetos son invernaderos. En la primera fase se podrían emplear diferentes métodos de segmentación o de detección de bordes. Sin embargo, dado que nuestro interés se centra en estudiar la efectividad de los diferentes descriptores de textura en la segunda fase, hemos sustituido la primera etapa por una delineación manual de la imagen. El interés de la aplicación práctica que nos ha ocupado se ha hecho patente desde el momento en el que la resolución espacial de las imágenes capturadas por los satélites de observación terrestre de última generación es muy superior a la que podían ofrecer hace algunos años. Mientras el tamaño de los píxeles era superior o del orden de los objetos de interés se utilizaron técnicas de análisis píxel a píxel o incluso de subpíxel, pero en la actualidad los objetos de interés suelen estar formados por varios píxeles, por lo que las técnicas basadas en análisis de objetos –denominadas *Object Based Image Analysis* (OBIA)–, están experimentando un notable crecimiento [32].

El número total de descriptores que hemos probado en este experimento asciende a un total de 24, tres menos que en el experimento de clasificación de imágenes de textura estacionaria al que nos referíamos en la Sección 4.3.1. Al igual que comentábamos entonces, los métodos que dependen de un parámetro se contabilizan como uno solo y los modelos  $CLBP\_S \otimes M \otimes C_{3 \times 3}$  y  $COOC_{3 \times 3}$  no se han podido utilizar en la práctica, debido a sus elevados requisitos computacionales. En este caso hemos decidido excluir igualmente nuestra implementación de las matrices de coocurrencia –a la que nos referíamos como  $HARALICK_{3 \times 3}$  en la sección anterior– y los modelos  $CLBP\_S/M_{3 \times 3}$  y  $CLBP\_S/M/C_{3 \times 3}$  porque el almacenamiento de un elevado número de histogramas de tan alta dimensión excedía la capacidad de memoria disponible.

Como se puede comprobar en la Tabla 4.3, las tasas de acierto obtenidas por los diferentes modelos considerados en el experimento están comprendidas entre el 87 y el 99% cuando se utilizan todos los polígonos delineados sobre la imagen. Hemos considerado oportuno repetir este experimento descartando los polígonos de menor tamaño, con el objetivo de determinar el posible efecto del problema conocido como ‘maldición de la dimensión’ [66], ya que resulta razonable pensar que cuando el número de píxeles de un polígono sea sensiblemente menor que la dimensión del vector de características, el poder de discriminación de los descriptores de alta dimensión pueda verse afectado por la aparición de numerosos nulos en los correspondientes histogramas. Hemos establecido un

Tabla 4.3: Porcentaje de polígonos correctamente clasificados.

Modelo	<i>Patches</i>	
	Todos	> 1000 píxeles
BGC1 <sub>3×3</sub>	98.40	99.24
BGC2 <sub>3×3</sub>	98.26	99.05
BGC3 <sub>3×3</sub>	97.66	98.11
BTCS+ <sub>3×3</sub>	94.46	95.08
CCR <sub>3×3</sub>	94.46	95.83
CLBP_M <sub>3×3</sub>	93.86	95.27
CLBP_M/C <sub>3×3</sub>	95.86	97.35
CLBP_S⊗M/C <sub>3×3</sub>	92.72	92.05
GLD <sub>3×3,6</sub>	87.98	87.12
GLTCS+ <sub>3×3</sub>	96.13	97.16
GTUC <sub>3×3,8</sub>	94.19	95.83
ILBP <sub>3×3</sub>	98.53	99.81
LBP <sub>3×3</sub>	98.66	98.86
LTP <sub>3×3,16</sub>	94.19	93.56
MTU16 <sub>3×3</sub>	96.66	96.59
MTU81 <sub>3×3</sub>	97.13	96.78
RANK <sub>3×3</sub>	91.72	89.96
RTU <sub>3×3</sub>	96.64	92.99
STS <sub>3×3</sub>	97.13	96.78
STU+ <sub>3×3,4</sub>	98.20	98.67
STU× <sub>3×3,2</sub>	97.66	99.24
TU0 <sub>3×3</sub>	93.52	92.99
TUΔ <sub>3×3,8</sub>	93.39	95.27
UNSER <sub>3×3</sub>	88.25	84.85

umbral de 1000 píxeles, lo que permite que los histogramas de la mayoría de los modelos ensayados estén suficientemente poblados. En este caso, el número resultante de objetos de las clases *greenhouse* y *nogreenhouse* se reduce a 394 y 134 respectivamente, lo que supone un 30,78 % y un 61,47 % del total de polígonos de cada clase que se muestra en la Figura 4.5. Los resultados que recogemos en la segunda columna de la Tabla 4.3 sugieren que no hay una correlación clara entre el tamaño de los polígonos y la tasa de acierto. Algunos descriptores alcanzan una mayor tasa de acierto al descartar los polígonos pequeños pero otros empeoran, aunque en conjunto se aprecie una tendencia hacia una leve mejora, como cabía esperar.



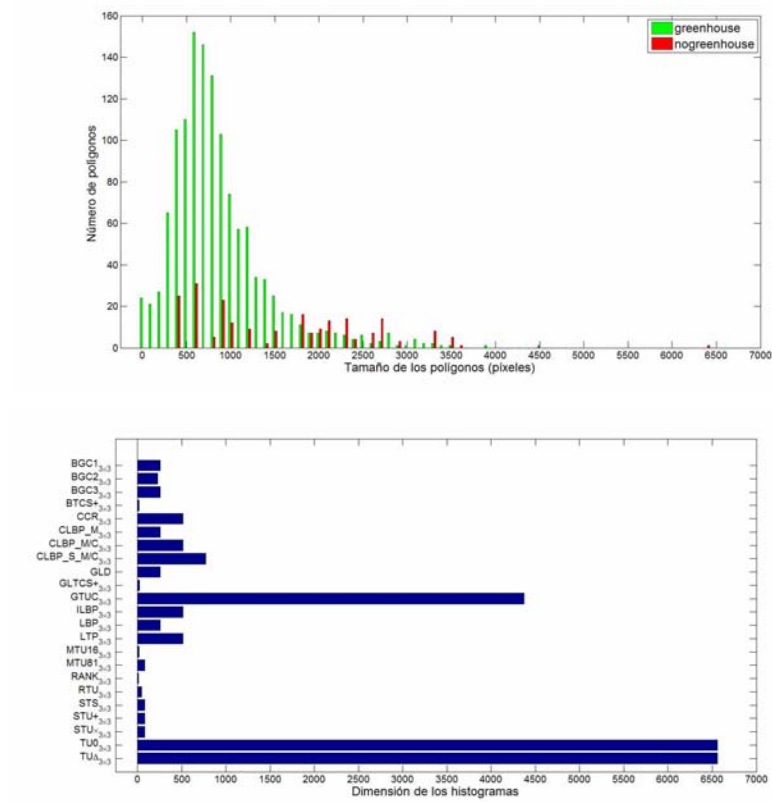


Figura 4.5: Distribución del tamaño de los polígonos empleados como *ground truth* y dimensión de los histogramas.

## Capítulo 5

# Conclusiones

El trabajo que hemos presentado a lo largo de esta memoria se encuadra dentro del análisis de texturas. A pesar del indudable interés que suscita esta línea de investigación, el concepto de textura –como hemos visto en el Capítulo 1– resulta subjetivo e impreciso, puesto que hasta el momento no se ha alcanzado una completa comprensión de los fenómenos psicofísicos que intervienen en la percepción de la textura. Esta situación se traduce en la dificultad que tradicionalmente ha entrañado la búsqueda de una definición cuantitativa y universal: somos capaces de reconocer la textura cuando la vemos, pero su formalización en términos concretos nos resulta complicada. En el lenguaje natural es habitual caracterizar cualitativamente la textura por medio de determinados adjetivos, lo que permite la distinción de dos o más texturas por comparación. Sin embargo, este enfoque resulta inapropiado para una disciplina como la visión por computador, cuyo fundamento es eminentemente matemático.

A lo largo de las últimas cuatro décadas se han propuesto numerosos métodos de caracterización de la textura, que consisten en representarla mediante un conjunto de valores numéricos calculados a partir de ciertos atributos de la imagen. La gran variedad de descriptores de textura que han aparecido hasta el momento dificulta considerablemente su categorización, máxime si tenemos en cuenta que las soluciones de tipo heurístico e incluso *ad hoc*, es decir orientadas a problemas concretos, son frecuentes. El principal problema que presenta cualquiera de las taxonomías propuestas es el solapamiento entre categorías que se produce, aunque en nuestra opinión, todas las técnicas de caracterización de la textura tienen un fundamento eminentemente estadístico.

Este panorama explica el reto que ha supuesto la búsqueda de un descriptor de textura óptimo en términos de poder de discriminación intrínseco e independiente de la aplicación en la que se utilice. Con frecuencia, este objetivo se ha abordado desde un enfoque comparativo, que consiste en enfrentar una nueva técnica con otras ya conocidas, para determinar si aquella es superior en función de un determinado factor de calidad, normalmente la tasa de acierto. Los estudios de este tipo son parciales porque solamente extienden la comparación a un conjunto limitado de descriptores de textura. Además, en estos trabajos se maneja un número también limitado de colecciones de imágenes, diferentes en cada caso, por lo que la extrapolación de los resultados obtenidos resulta inviable.

En vista de las dificultades que entraña la determinación de una solución

universal al problema de la caracterización de la textura, en esta tesis nos hemos fijado como objetivo principal el estudio de una categoría particular de descriptores. Se trata de aquellos que representan la textura mediante un histograma cuya dimensión se reduce estableciendo una relación de equivalencia entre patrones. Esta categorización supone una novedad, puesto que hasta la fecha no se había tenido en cuenta que todas las técnicas incluidas en ella comparten el mismo principio de funcionamiento, y por lo tanto se había considerado que pertenecían a categorías diferentes. Además, hemos aportado una interpretación novedosa de algunos modelos que a primera vista no tienen conexión alguna con las demás técnicas incluidas en el modelo unificado, como es el caso de las populares matrices de coocurrencia de Haralick. Una de nuestras principales contribuciones ha sido precisamente proponer un nuevo modelo teórico—descrito en el Capítulo 2— capaz de unificar y sintetizar mediante una notación compacta los principios comunes a este tipo de descriptores. El uso de una notación unificada permite poner de relieve los fuertes lazos que, como de hecho hemos demostrado, existen entre estos modelos de textura.

El núcleo del modelo unificado que proponemos destaca por su flexibilidad, que se manifiesta en una doble vertiente. En primer lugar, la construcción del histograma de patrones equivalentes se puede hacer particularizando la relación de equivalencia genérica según tres esquemas básicos: marginalización, umbralización u ordenación. En segundo lugar, se trata de un modelo extensible que admite nuevas vías de ampliación para alcanzar un marco más general. De este modo hemos abierto seis posibles líneas de extensión, en las que se englobarían técnicas ya existentes que quedan fuera del núcleo del modelo unificado, pero que están estrechamente relacionadas con éste.

Por otra parte, en el Capítulo 3 hemos presentado una nueva familia de descriptores de textura, a la que hemos denominado Gradientes Binarios de Contorno o *Binary Gradient Contours* (BGC), como ejemplo de particularización por umbralización del modelo unificado, lo que nos ha permitido contrastar su potencia y su capacidad de generalización. Todos los modelos BGC destacan por su simplicidad teórica, así como por su reducido coste computacional. Además hemos analizado la eficiencia teórica de los modelos BGC calculando la entropía del histograma que estima la probabilidad *a priori* de las clases de equivalencia y la hemos comparado con la correspondiente al modelo LBP, lo que nos ha permitido concluir que los tres representantes de la familia BGC contienen una mayor cantidad de información que el histograma LBP. Esto también constituye una aportación novedosa, puesto que es poco frecuente encontrar en la literatura trabajos en los que se comparen descriptores de textura desde un punto de vista teórico.

La actividad experimental que hemos desarrollado se ha centrado en imágenes de textura estacionaria e imágenes de satélite de alta resolución. Por una parte hemos utilizado 10 bases de datos formadas por imágenes de textura estacionaria, nueve de las cuales se encuentran disponibles en Internet, mientras que la décima fue elaborada por miembros de nuestro grupo de investigación. Con estas imágenes hemos realizado un experimento de clasificación supervisada. Por otra parte, hemos desarrollado un experimento de clasificación de objetos sobre una imagen de satélite de alta resolución, con el fin de estudiar la viabilidad de introducir descriptores de textura en un problema presente en el ámbito de la teledetección como es la detección automática de invernaderos. De este modo hemos completado un riguroso estudio comparativo que, por lo que sabemos, es

el más amplio realizado hasta el momento, lo que implica que las conclusiones que se extraen de nuestro trabajo tengan un carácter más general que las de otras publicaciones anteriores.

La bondad de un determinado descriptor de textura se suele analizar teniendo en cuenta exclusivamente la tasa de acierto que alcanza. Sin embargo, la valoración que aporta este índice por sí solo es parcial, puesto que no contempla aspectos muy relevantes como el tiempo de cómputo, que es un factor crucial en aplicaciones de tiempo real. Con el fin de determinar las técnicas que presentan un mejor comportamiento combinado, el criterio de selección que hemos desarrollado en esta tesis se basa en relacionar la dimensión, la tasa de acierto y el tiempo de cómputo de cada descriptor con las medianas de las distribuciones correspondientes sobre las 10 bases de datos consideradas. Además, para estudiar si las diferencias existentes entre las tasas de acierto de los diferentes descriptores son significativas se realizó un análisis estadístico de hipótesis basado en el test de los rangos con signo de Wilcoxon.

Los resultados obtenidos –detallados en el Capítulo 4 y en el Apéndice A– demuestran que todos los descriptores analizados proporcionan un comportamiento satisfactorio, aunque existen notables diferencias de uno a otro. Cinco de las 27 técnicas analizadas en el experimento de clasificación de texturas estacionarias cumplen simultáneamente las tres condiciones que, según el criterio que hemos seguido en esta tesis, son deseables para cualquier descriptor de textura, a saber: una elevada tasa de acierto, un tiempo de ejecución reducido y una dimensión moderada. Cabe destacar que dos de estos cinco mejores modelos pertenecen a la familia BGC, lo que demuestra las buenas expectativas que se derivaban del análisis de su eficiencia teórica, siendo la BGC1 el método no paramétrico que obtiene un mayor número de victorias en el test de Wilcoxon. En el experimento de clasificación de objetos que hemos realizado sobre la imagen de satélite los resultados son equiparables. En este caso hemos observado que los tres descriptores que obtienen una mejor tasa de acierto son la ILBP, la BGC1 y la LBP, lo que nos induce a pensar que, una versión mejorada (*improved*) de la BGC, es decir, que tenga en cuenta el píxel central de cada patrón  $3 \times 3$  en el cómputo del código, probablemente se situaría a la cabeza de esta terna.

En definitiva, el modelo unificado que presentamos en esta tesis nos ha permitido sistematizar el análisis de un amplio abanico de descriptores de textura que hasta el momento se habían estudiado de manera parcial e inconexa. En un futuro inmediato será posible derivar nuevas técnicas a partir del núcleo particularizando la relación de equivalencia genérica en torno a la cual se organiza el marco teórico. Por otra parte, dicho modelo es extensible, de modo que se abren diferentes líneas de investigación para agregar más capas al núcleo. Como consecuencia, sería posible efectuar estudios comparativos de mayor alcance, en los que se incluirían distintas versiones de los descriptores de textura aquí analizados. De especial interés resultará la generalización del modelo unificado a un tamaño de ventana mayor que  $3 \times 3$  y la búsqueda de un criterio que permita determinar cuál es la partición del espacio de patrones más adecuada para derivar el descriptor óptimo. Para finalizar, estas posibilidades de desarrollo futuro se completarían con el diseño e implementación de nuevos experimentos, que permitirían estudiar y validar el comportamiento de los diferentes descriptores de textura ante otros problemas canónicos de gran interés en aplicaciones reales, como puede ser la segmentación o la recuperación de imágenes basada en contenido (CBIR).



# APÉNDICES



## Apéndice A

# Bases de datos y resultados

En este apéndice incluimos información detallada acerca del experimento de clasificación de imágenes que hemos realizado sobre las 10 colecciones de texturas estacionarias que describíamos en las Secciones 4.1.1 y 4.1.2. Por una parte, hemos desglosado en una serie de tablas los resultados obtenidos por los descriptores de textura que encajan en el modelo unificado desarrollado a lo largo de esta tesis. Estas tablas agrupan a los descriptores según el tipo de correspondencia al que pertenecen, tal y como exponíamos en la Sección 2.3: marginalización, umbralización y ordenación. De este modo, el número total de tablas asciende a 30, es decir, tres tablas por cada una de las 10 bases de datos (Tablas A.1-A.30). Por otra parte, hemos creado 10 figuras en forma de mosaico donde se muestran las imágenes que conforman cada una de las bases de datos consideradas (Figuras A.1-A.10). La información relativa a cada base de datos ocupa dos páginas. En las páginas impares del apéndice se pueden encontrar las tablas de resultados correspondientes a las técnicas de marginalización y ordenación, así como el mosaico de imágenes. En las pares, exceptuando esta página introductoria, se recogen los resultados obtenidos por las técnicas de umbralización.

Todas las tablas que aparecen en este apéndice tienen la misma estructura. En la primera columna se listan los códigos alfanuméricos con los que identificamos a los distintos descriptores de textura. En la segunda columna se recoge el promedio de la tasa de acierto obtenida para los 100 problemas aleatorios en los que se divide el experimento, cuya expresión mostrábamos en la Ecuación 4.8. Este dato se completa en la tercera, cuarta y quinta columna con la desviación típica insesgada (Ecuación 4.9), el valor máximo ( $t_{\text{máx}}$ ) y el valor mínimo ( $t_{\text{mín}}$ ) respectivamente. Finalmente, en la sexta columna ofrecemos una medida cualitativa de la complejidad computacional de los descriptores de textura. Se trata del tiempo de ejecución ( $T$ ), que, para cada base de datos, se ha normalizado con respecto al menor valor, lo que facilita la comparación de todas las técnicas consideradas. De este modo, dicha columna representará una magnitud adimensional y siempre existirá como mínimo un descriptor cuyo tiempo de ejecución normalizado tome el valor 1.0.

A continuación se muestran los resultados de las bases de datos en el siguiente orden: Brodatz, Jerry Wu, KTH-TIPS, KTH-TIPS2b, Mondial Marmi, Outex TC\_00000, Outex TC\_00001, Outex TC\_00013, UIUCtex y VisTex.



## A.1. Brodatz

Tabla A.1: Resultados: Brodatz y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	80.57	2.69	88.46	74.04	1.1
GLD $_{3 \times 3, 6}$	72.45	3.78	84.62	64.42	1.1
GLD $_{3 \times 3, 5}$	80.67	2.82	86.54	74.04	1.1
GLD $_{3 \times 3, 4}$	81.72	2.77	89.42	73.08	1.1
GLD $_{3 \times 3, 3}$	80.57	2.69	88.46	74.04	1.1
GLD $_{3 \times 3, 2}$	72.45	3.78	84.62	64.42	1.1
GLD $_{3 \times 3, 1}$	80.67	2.82	86.54	74.04	1.1
GLD $_{3 \times 3, 0}$	81.72	2.77	89.42	73.08	1.1
HARALICK $_{3 \times 3}$	96.92	1.77	100.00	89.42	129.3
UNSER $_{3 \times 3}$	97.88	1.56	100.00	91.35	25.3

Tabla A.2: Resultados: Brodatz y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS+ $_{3 \times 3}$	97.98	1.25	100.00	94.23	1.7
RANK $_{3 \times 3}$	99.97	0.16	100.00	99.04	1.2




Figura A.1: Texturas de la base de datos de Brodatz USC-SIPI.

Tabla A.3: Resultados: Brodatz y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC1 <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.4
BGC2 <sub>3×3</sub>	99.39	0.65	100.00	98.08	1.4
BGC3 <sub>3×3</sub>	99.80	0.42	100.00	98.08	1.4
BTCS+ <sub>3×3</sub>	96.23	1.81	100.00	91.35	1.5
CCR <sub>3×3</sub>	98.76	1.15	100.00	95.19	2.0
CLBP_M <sub>3×3</sub>	98.81	1.04	100.00	96.15	1.7
CLBP_M/C <sub>3×3</sub>	99.83	0.44	100.00	98.08	1.9
CLBP_S/M <sub>3×3</sub>	100.00	0.00	100.00	100.00	46.0
CLBP_S⊗M/C <sub>3×3</sub>	100.00	0.00	100.00	100.00	2.7
CLBP_S/M/C <sub>3×3</sub>	100.00	0.00	100.00	100.00	96.6
GTUC <sub>3×3,1</sub>	73.21	3.85	80.77	62.50	5.0
GTUC <sub>3×3,2</sub>	87.74	2.59	94.23	81.73	5.4
GTUC <sub>3×3,4</sub>	95.67	1.76	99.04	90.38	5.8
GTUC <sub>3×3,8</sub>	97.88	1.29	100.00	95.19	6.2
GTUC <sub>3×3,16</sub>	98.41	1.23	100.00	94.23	5.9
GTUC <sub>3×3,32</sub>	89.89	2.58	96.15	84.62	5.1
ILBP <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.8
LBP <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.4
LTP <sub>3×3,1</sub>	100.00	0.00	100.00	100.00	2.4
LTP <sub>3×3,2</sub>	100.00	0.00	100.00	100.00	2.3
LTP <sub>3×3,4</sub>	100.00	0.00	100.00	100.00	2.3
LTP <sub>3×3,8</sub>	99.99	0.10	100.00	99.04	2.4
LTP <sub>3×3,16</sub>	99.81	0.53	100.00	97.12	2.2
LTP <sub>3×3,32</sub>	95.53	2.32	100.00	88.46	2.0
MTU16 <sub>3×3</sub>	97.48	1.59	100.00	93.27	1.0
MTU81 <sub>3×3</sub>	99.33	0.70	100.00	96.15	1.4
RTU <sub>3×3</sub>	99.79	0.48	100.00	97.12	4.2
STS <sub>3×3</sub>	99.33	0.70	100.00	96.15	1.4
STU+ <sub>3×3,1</sub>	99.93	0.25	100.00	99.04	1.4
STU+ <sub>3×3,2</sub>	99.95	0.21	100.00	99.04	1.4
STU+ <sub>3×3,4</sub>	99.96	0.19	100.00	99.04	1.5
STU+ <sub>3×3,8</sub>	99.78	0.49	100.00	97.12	1.4
STU+ <sub>3×3,16</sub>	98.70	1.23	100.00	95.19	1.3
STU+ <sub>3×3,32</sub>	86.72	3.43	94.23	73.08	1.3
STU× <sub>3×3,1</sub>	99.97	0.21	100.00	98.08	1.4
STU× <sub>3×3,2</sub>	99.97	0.21	100.00	98.08	1.4
STU× <sub>3×3,4</sub>	99.96	0.19	100.00	99.04	1.4
STU× <sub>3×3,8</sub>	99.95	0.25	100.00	98.08	1.4
STU× <sub>3×3,16</sub>	99.68	0.76	100.00	96.15	1.4
STU× <sub>3×3,32</sub>	91.29	2.81	98.08	82.69	1.3
TU0 <sub>3×3</sub>	100.00	0.00	100.00	100.00	5.3
TUΔ <sub>3×3,1</sub>	100.00	0.00	100.00	100.00	5.4
TUΔ <sub>3×3,2</sub>	100.00	0.00	100.00	100.00	5.4
TUΔ <sub>3×3,4</sub>	99.99	0.10	100.00	99.04	5.5
TUΔ <sub>3×3,8</sub>	99.95	0.25	100.00	98.08	5.4
TUΔ <sub>3×3,16</sub>	99.80	0.63	100.00	96.15	5.4
TUΔ <sub>3×3,32</sub>	95.00	2.30	99.04	88.46	5.1

## A.2. Jerry Wu

Tabla A.4: Resultados: Jerry Wu y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	55.47	4.23	67.95	42.31	1.1
GLD $_{3 \times 3, 6}$	48.85	4.34	57.69	38.46	1.1
GLD $_{3 \times 3, 5}$	50.38	4.43	60.26	38.46	1.1
GLD $_{3 \times 3, 4}$	61.19	3.85	71.79	52.56	1.0
GLD $_{3 \times 3, 3}$	55.47	4.23	67.95	42.31	1.0
GLD $_{3 \times 3, 2}$	48.85	4.34	57.69	38.46	1.0
GLD $_{3 \times 3, 1}$	50.38	4.43	60.26	38.46	1.0
GLD $_{3 \times 3, 0}$	61.19	3.85	71.79	52.56	1.0
HARALICK $_{3 \times 3}$	68.14	6.38	87.18	48.72	130.2
UNSER $_{3 \times 3}$	72.60	6.15	89.74	56.41	24.5

Tabla A.5: Resultados: Jerry Wu y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	93.10	2.39	98.72	88.46	1.7
RANK $_{3 \times 3}$	91.13	1.98	94.87	85.90	1.2




Figura A.2: Texturas de la base de datos de Jerry Wu.

Tabla A.6: Resultados: Jerry Wu y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC $1_{3 \times 3}$	97.59	1.46	100.00	93.59	1.4
BGC $2_{3 \times 3}$	97.09	1.50	100.00	93.59	1.4
BGC $3_{3 \times 3}$	98.21	1.15	100.00	94.87	1.3
BTCS $+_{3 \times 3}$	84.58	3.16	93.59	78.21	1.5
CCR $_{3 \times 3}$	93.71	2.20	98.72	88.46	1.9
CLBP $_M_{3 \times 3}$	94.73	2.22	98.72	89.74	1.6
CLBP $_M/C_{3 \times 3}$	97.60	1.56	100.00	92.31	1.8
CLBP $_S/M_{3 \times 3}$	99.22	0.93	100.00	96.15	43.9
CLBP $_S \otimes M/C_{3 \times 3}$	98.51	1.37	100.00	94.87	2.6
CLBP $_S/M/C_{3 \times 3}$	99.37	0.80	100.00	97.44	94.2
GTUC $_{3 \times 3,1}$	64.40	3.52	73.08	57.69	5.1
GTUC $_{3 \times 3,2}$	81.19	3.88	89.74	70.51	5.6
GTUC $_{3 \times 3,4}$	89.67	3.33	97.44	80.77	6.0
GTUC $_{3 \times 3,8}$	91.27	2.94	97.44	80.77	6.1
GTUC $_{3 \times 3,16}$	82.63	3.29	89.74	71.79	5.5
GTUC $_{3 \times 3,32}$	60.00	5.02	71.79	47.44	5.1
ILBP $_{3 \times 3}$	97.77	1.61	100.00	93.59	1.7
LBP $_{3 \times 3}$	97.26	1.55	100.00	93.59	1.4
LTP $_{3 \times 3,1}$	97.26	1.55	100.00	93.59	2.3
LTP $_{3 \times 3,2}$	97.50	1.62	100.00	93.59	2.3
LTP $_{3 \times 3,4}$	98.06	1.33	100.00	94.87	2.3
LTP $_{3 \times 3,8}$	96.54	1.87	100.00	92.31	2.2
LTP $_{3 \times 3,16}$	87.03	3.30	94.87	74.36	2.0
LTP $_{3 \times 3,32}$	66.78	4.99	79.49	53.85	2.0
MTU16 $_{3 \times 3}$	91.71	2.41	97.44	84.62	1.0
MTU81 $_{3 \times 3}$	94.82	1.83	100.00	91.03	1.4
RTU $_{3 \times 3}$	94.40	2.77	98.72	84.62	4.0
STS $_{3 \times 3}$	94.82	1.83	100.00	91.03	1.4
STU $+_{3 \times 3,1}$	97.06	1.47	98.72	92.31	1.4
STU $+_{3 \times 3,2}$	96.56	1.81	100.00	91.03	1.4
STU $+_{3 \times 3,4}$	96.58	1.84	100.00	92.31	1.4
STU $+_{3 \times 3,8}$	93.33	2.63	98.72	87.18	1.4
STU $+_{3 \times 3,16}$	76.72	4.83	85.90	62.82	1.3
STU $+_{3 \times 3,32}$	52.86	4.93	64.10	41.03	1.4
STU $\times_{3 \times 3,1}$	98.06	1.23	100.00	92.31	1.4
STU $\times_{3 \times 3,2}$	98.68	1.04	100.00	94.87	1.4
STU $\times_{3 \times 3,4}$	98.71	1.07	100.00	96.15	1.4
STU $\times_{3 \times 3,8}$	94.26	2.32	98.72	88.46	1.4
STU $\times_{3 \times 3,16}$	84.81	3.01	91.03	78.21	1.3
STU $\times_{3 \times 3,32}$	62.64	4.91	75.64	50.00	1.3
TU0 $_{3 \times 3}$	97.71	1.47	100.00	94.87	5.4
TU $\Delta_{3 \times 3,1}$	98.06	1.54	100.00	93.59	5.5
TU $\Delta_{3 \times 3,2}$	98.28	1.37	100.00	94.87	5.5
TU $\Delta_{3 \times 3,4}$	98.54	1.15	100.00	96.15	5.6
TU $\Delta_{3 \times 3,8}$	97.51	1.84	100.00	93.59	5.5
TU $\Delta_{3 \times 3,16}$	89.91	2.59	96.15	83.33	5.3
TU $\Delta_{3 \times 3,32}$	68.03	4.53	79.49	55.13	5.4

### A.3. KTH-TIPS

Tabla A.7: Resultados: KTH-TIPS y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3,7}$	87.40	4.35	95.00	75.00	1.2
GLD $_{3 \times 3,6}$	85.10	4.44	95.00	75.00	1.1
GLD $_{3 \times 3,5}$	83.00	4.32	90.00	70.00	1.1
GLD $_{3 \times 3,4}$	91.80	5.53	100.00	80.00	1.1
GLD $_{3 \times 3,3}$	87.40	4.35	95.00	75.00	1.1
GLD $_{3 \times 3,2}$	85.10	4.44	95.00	75.00	1.1
GLD $_{3 \times 3,1}$	83.00	4.32	90.00	70.00	1.1
GLD $_{3 \times 3,0}$	91.80	5.53	100.00	80.00	1.1
HARALICK $_{3 \times 3}$	93.00	7.25	100.00	75.00	120.5
UNSER $_{3 \times 3}$	94.05	6.95	100.00	75.00	15.7

Tabla A.8: Resultados: KTH-TIPS y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	96.70	4.73	100.00	85.00	1.4
RANK $_{3 \times 3}$	100.00	0.00	100.00	100.00	1.1



Figura A.3: Texturas de la base de datos KTH-TIPS.

Tabla A.9: Resultados: KTH-TIPS y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC1 <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.1
BGC2 <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.1
BGC3 <sub>3×3</sub>	99.10	2.06	100.00	90.00	1.1
BTCS+ <sub>3×3</sub>	98.55	2.59	100.00	90.00	2.2
CCR <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.5
CLBP_M <sub>3×3</sub>	99.65	1.28	100.00	95.00	1.2
CLBP_M/C <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.3
CLBP_S/M <sub>3×3</sub>	98.15	2.72	100.00	90.00	36.6
CLBP_S⊗M/C <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.6
CLBP_S/M/C <sub>3×3</sub>	97.30	2.50	100.00	95.00	77.1
GTUC <sub>3×3,1</sub>	79.10	6.49	95.00	65.00	3.0
GTUC <sub>3×3,2</sub>	88.85	6.15	100.00	75.00	3.1
GTUC <sub>3×3,4</sub>	98.75	2.18	100.00	95.00	3.3
GTUC <sub>3×3,8</sub>	98.00	2.66	100.00	90.00	3.4
GTUC <sub>3×3,16</sub>	96.50	3.92	100.00	90.00	3.4
GTUC <sub>3×3,32</sub>	88.25	4.46	95.00	80.00	3.2
ILBP <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.3
LBP <sub>3×3</sub>	100.00	0.00	100.00	100.00	1.2
LTP <sub>3×3,1</sub>	100.00	0.00	100.00	100.00	1.5
LTP <sub>3×3,2</sub>	100.00	0.00	100.00	100.00	1.5
LTP <sub>3×3,4</sub>	100.00	0.00	100.00	100.00	1.5
LTP <sub>3×3,8</sub>	100.00	0.00	100.00	100.00	1.5
LTP <sub>3×3,16</sub>	99.55	1.44	100.00	95.00	1.5
LTP <sub>3×3,32</sub>	93.95	4.51	100.00	85.00	1.4
MTU16 <sub>3×3</sub>	91.30	5.53	100.00	80.00	1.0
MTU81 <sub>3×3</sub>	99.15	1.89	100.00	95.00	1.1
RTU <sub>3×3</sub>	97.65	2.51	100.00	95.00	2.5
STS <sub>3×3</sub>	99.15	1.89	100.00	95.00	1.1
STU+ <sub>3×3,1</sub>	100.00	0.00	100.00	100.00	1.1
STU+ <sub>3×3,2</sub>	99.75	1.10	100.00	95.00	1.1
STU+ <sub>3×3,4</sub>	99.85	0.86	100.00	95.00	1.1
STU+ <sub>3×3,8</sub>	99.85	0.86	100.00	95.00	1.2
STU+ <sub>3×3,16</sub>	96.55	3.07	100.00	85.00	1.1
STU+ <sub>3×3,32</sub>	88.85	4.37	95.00	80.00	1.1
STU× <sub>3×3,1</sub>	100.00	0.00	100.00	100.00	1.1
STU× <sub>3×3,2</sub>	100.00	0.00	100.00	100.00	1.1
STU× <sub>3×3,4</sub>	100.00	0.00	100.00	100.00	1.2
STU× <sub>3×3,8</sub>	100.00	0.00	100.00	100.00	1.2
STU× <sub>3×3,16</sub>	95.65	4.85	100.00	85.00	1.1
STU× <sub>3×3,32</sub>	89.65	4.40	100.00	80.00	1.1
TU0 <sub>3×3</sub>	100.00	0.00	100.00	100.00	3.7
TUΔ <sub>3×3,1</sub>	99.90	0.70	100.00	95.00	3.6
TUΔ <sub>3×3,2</sub>	100.00	0.00	100.00	100.00	3.7
TUΔ <sub>3×3,4</sub>	100.00	0.00	100.00	100.00	3.7
TUΔ <sub>3×3,8</sub>	100.00	0.00	100.00	100.00	3.7
TUΔ <sub>3×3,16</sub>	99.25	1.79	100.00	95.00	3.6
TUΔ <sub>3×3,32</sub>	93.40	4.71	100.00	85.00	3.5

## A.4. KTH-TIPS2b

Tabla A.10: Resultados: KTH-TIPS2b y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	72.49	4.17	81.82	62.50	1.1
GLD $_{3 \times 3, 6}$	67.77	4.59	77.27	51.14	1.1
GLD $_{3 \times 3, 5}$	70.43	4.34	80.68	55.68	1.1
GLD $_{3 \times 3, 4}$	70.31	4.52	81.82	55.68	1.2
GLD $_{3 \times 3, 3}$	72.49	4.17	81.82	62.50	1.1
GLD $_{3 \times 3, 2}$	67.77	4.59	77.27	51.14	1.1
GLD $_{3 \times 3, 1}$	70.43	4.34	80.68	55.68	1.1
GLD $_{3 \times 3, 0}$	70.31	4.52	81.82	55.68	1.1
HARALICK $_{3 \times 3}$	83.61	4.14	92.05	73.86	144.0
UNSER $_{3 \times 3}$	88.08	4.07	95.45	75.00	29.3

Tabla A.11: Resultados: KTH-TIPS2b y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	72.26	4.47	82.95	61.36	1.3
RANK $_{3 \times 3}$	77.10	3.66	84.09	65.91	1.0



Figura A.4: Texturas de la base de datos KTH-TIPS2b.

Tabla A.12: Resultados: KTH-TIPS2b y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC $1_{3 \times 3}$	90.33	3.45	96.59	79.55	1.2
BGC $2_{3 \times 3}$	82.82	3.95	93.18	71.59	1.2
BGC $3_{3 \times 3}$	84.64	3.69	94.32	71.59	1.2
BTCS $+_{3 \times 3}$	78.06	4.54	89.77	67.05	1.2
CCR $_{3 \times 3}$	84.43	4.64	94.32	70.45	1.5
CLBP_M $_{3 \times 3}$	82.95	3.93	92.05	71.59	1.2
CLBP_M/C $_{3 \times 3}$	92.10	3.46	98.86	82.95	1.4
CLBP_S/M $_{3 \times 3}$	89.36	3.54	95.45	80.68	63.4
CLBP_S $\otimes$ M/C $_{3 \times 3}$	94.51	2.83	98.86	86.36	1.7
CLBP_S/M/C $_{3 \times 3}$	86.99	3.62	95.45	77.27	136.6
GTUC $_{3 \times 3,1}$	66.72	4.42	75.00	53.41	3.6
GTUC $_{3 \times 3,2}$	77.26	4.30	85.23	62.50	3.8
GTUC $_{3 \times 3,4}$	81.51	4.22	89.77	68.18	3.9
GTUC $_{3 \times 3,8}$	86.56	4.50	94.32	70.45	4.0
GTUC $_{3 \times 3,16}$	85.91	4.24	94.32	73.86	3.9
GTUC $_{3 \times 3,32}$	74.50	4.87	82.95	57.95	3.8
ILBP $_{3 \times 3}$	91.86	2.95	96.59	82.95	1.3
LBP $_{3 \times 3}$	89.68	3.46	95.45	78.41	1.2
LTP $_{3 \times 3,1}$	90.05	3.52	96.59	78.41	1.5
LTP $_{3 \times 3,2}$	90.39	3.39	96.59	81.82	1.5
LTP $_{3 \times 3,4}$	92.92	3.24	98.86	81.82	1.5
LTP $_{3 \times 3,8}$	93.48	3.53	97.73	82.95	1.5
LTP $_{3 \times 3,16}$	91.16	3.99	97.73	78.41	1.5
LTP $_{3 \times 3,32}$	84.20	4.76	94.32	67.05	1.5
MTU16 $_{3 \times 3}$	75.30	4.25	82.95	65.91	1.0
MTU81 $_{3 \times 3}$	82.33	4.13	89.77	68.18	1.1
RTU $_{3 \times 3}$	82.36	4.37	92.05	70.45	2.4
STS $_{3 \times 3}$	82.32	4.15	89.77	68.18	1.1
STU $+_{3 \times 3,1}$	87.35	3.92	93.18	76.14	1.1
STU $+_{3 \times 3,2}$	89.61	3.95	97.73	78.41	1.1
STU $+_{3 \times 3,4}$	91.22	3.92	98.86	79.55	1.1
STU $+_{3 \times 3,8}$	91.51	3.93	98.86	79.55	1.1
STU $+_{3 \times 3,16}$	89.31	4.30	96.59	75.00	1.1
STU $+_{3 \times 3,32}$	77.30	5.06	89.77	65.91	1.4
STU $\times_{3 \times 3,1}$	90.67	3.19	97.73	80.68	1.1
STU $\times_{3 \times 3,2}$	90.74	3.42	97.73	81.82	1.1
STU $\times_{3 \times 3,4}$	92.20	3.71	97.73	79.55	1.1
STU $\times_{3 \times 3,8}$	91.57	3.51	97.73	78.41	1.1
STU $\times_{3 \times 3,16}$	89.44	3.97	96.59	75.00	1.1
STU $\times_{3 \times 3,32}$	82.17	4.43	93.18	69.32	1.1
TU0 $_{3 \times 3}$	89.80	3.65	95.45	77.27	4.7
TU $\Delta_{3 \times 3,1}$	90.44	3.71	96.59	79.55	4.7
TU $\Delta_{3 \times 3,2}$	92.55	3.30	98.86	82.95	4.7
TU $\Delta_{3 \times 3,4}$	93.82	3.32	100.00	82.95	4.7
TU $\Delta_{3 \times 3,8}$	92.64	3.59	97.73	82.95	4.7
TU $\Delta_{3 \times 3,16}$	90.85	3.91	97.73	78.41	4.6
TU $\Delta_{3 \times 3,32}$	82.56	4.58	93.18	68.18	4.6



## A.5. Mondial Marmi

Tabla A.13: Resultados: Mondial Marmi y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3,7}$	56.60	1.59	61.98	52.86	1.3
GLD $_{3 \times 3,6}$	62.07	1.82	66.67	58.59	1.3
GLD $_{3 \times 3,5}$	58.22	1.73	64.06	54.17	1.2
GLD $_{3 \times 3,4}$	54.20	1.97	58.59	48.96	1.2
GLD $_{3 \times 3,3}$	56.60	1.59	61.98	52.86	1.2
GLD $_{3 \times 3,2}$	62.07	1.82	66.67	58.59	1.2
GLD $_{3 \times 3,1}$	58.22	1.73	64.06	54.17	1.2
GLD $_{3 \times 3,0}$	54.20	1.97	58.59	48.96	1.3
HARALICK $_{3 \times 3}$	88.52	1.46	91.41	84.64	226.1
UNSER $_{3 \times 3}$	91.77	1.11	94.53	88.80	72.3

Tabla A.14: Resultados: Mondial Marmi y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	66.91	1.75	72.66	62.24	1.4
RANK $_{3 \times 3}$	67.06	1.81	71.88	63.02	1.0



Figura A.5: Texturas de la base de datos de Mondial Marmi.

Tabla A.15: Resultados: Mondial Marmi y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC $1_{3 \times 3}$	82.67	1.57	86.98	79.43	1.4
BGC $2_{3 \times 3}$	75.41	1.56	79.69	71.35	1.3
BGC $3_{3 \times 3}$	76.93	1.71	81.77	73.18	1.3
BTCS $+_{3 \times 3}$	72.01	1.59	75.52	68.75	1.9
CCR $_{3 \times 3}$	80.88	1.44	84.11	76.56	1.9
CLBP $_M_{3 \times 3}$	80.85	1.52	84.64	77.08	1.4
CLBP $_M/C_{3 \times 3}$	85.83	1.43	90.36	83.33	1.7
CLBP $_S/M_{3 \times 3}$	79.09	1.85	84.64	75.52	145.5
CLBP $_S \otimes M/C_{3 \times 3}$	91.91	1.16	95.31	89.32	2.3
CLBP $_S/M/C_{3 \times 3}$	80.23	1.97	85.16	74.22	316.0
GTUC $_{3 \times 3,1}$	47.93	1.71	52.08	43.49	11.0
GTUC $_{3 \times 3,2}$	65.22	1.77	69.01	61.20	11.0
GTUC $_{3 \times 3,4}$	76.18	1.65	79.95	71.35	11.3
GTUC $_{3 \times 3,8}$	82.57	1.54	86.46	79.17	11.3
GTUC $_{3 \times 3,16}$	79.11	1.55	82.55	75.26	11.1
GTUC $_{3 \times 3,32}$	61.94	2.21	67.19	51.82	12.3
ILBP $_{3 \times 3}$	86.08	1.50	89.58	82.55	1.7
LBP $_{3 \times 3}$	83.42	1.46	86.98	79.17	1.3
LTP $_{3 \times 3,1}$	84.52	1.27	87.50	80.99	1.9
LTP $_{3 \times 3,2}$	87.47	1.32	90.63	83.85	1.9
LTP $_{3 \times 3,4}$	88.39	1.34	90.89	83.59	1.9
LTP $_{3 \times 3,8}$	88.16	1.36	91.41	83.85	1.9
LTP $_{3 \times 3,16}$	83.82	1.49	87.76	80.47	1.8
LTP $_{3 \times 3,32}$	64.49	2.30	69.01	53.65	3.3
MTU16 $_{3 \times 3}$	69.24	1.63	72.40	64.58	1.0
MTU81 $_{3 \times 3}$	74.07	1.86	78.13	69.79	1.2
RTU $_{3 \times 3}$	74.57	1.65	77.86	68.49	2.9
STS $_{3 \times 3}$	74.03	1.85	78.13	69.79	1.1
STU $+_{3 \times 3,1}$	83.00	1.54	87.24	79.95	1.2
STU $+_{3 \times 3,2}$	85.85	1.35	89.06	82.29	1.2
STU $+_{3 \times 3,4}$	87.27	1.46	91.41	82.03	1.2
STU $+_{3 \times 3,8}$	84.34	1.57	88.28	80.47	1.2
STU $+_{3 \times 3,16}$	79.35	1.79	83.07	75.26	2.0
STU $+_{3 \times 3,32}$	61.09	2.26	65.36	51.56	2.7
STU $\times_{3 \times 3,1}$	83.48	1.35	86.46	80.73	1.2
STU $\times_{3 \times 3,2}$	86.88	1.29	89.32	83.85	1.2
STU $\times_{3 \times 3,4}$	89.09	1.35	91.93	84.64	1.2
STU $\times_{3 \times 3,8}$	88.27	1.30	91.41	85.16	1.2
STU $\times_{3 \times 3,16}$	80.58	1.52	84.64	77.08	1.2
STU $\times_{3 \times 3,32}$	61.43	2.64	66.67	50.26	2.7
TU0 $_{3 \times 3}$	85.22	1.47	88.80	81.25	15.2
TU $\Delta_{3 \times 3,1}$	87.02	1.52	90.89	83.59	15.4
TU $\Delta_{3 \times 3,2}$	89.66	1.42	94.01	86.46	15.3
TU $\Delta_{3 \times 3,4}$	89.00	1.30	93.23	86.46	15.4
TU $\Delta_{3 \times 3,8}$	87.09	1.41	90.10	83.59	15.3
TU $\Delta_{3 \times 3,16}$	82.39	1.63	86.46	78.13	15.3
TU $\Delta_{3 \times 3,32}$	63.39	2.38	67.97	52.34	16.7

## A.6. Outex TC\_00000

Tabla A.16: Resultados: Outex TC\_00000 y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	57.19	2.56	64.58	52.92	1.2
GLD $_{3 \times 3, 6}$	60.86	2.42	65.83	55.83	1.2
GLD $_{3 \times 3, 5}$	53.57	2.46	59.17	46.67	1.2
GLD $_{3 \times 3, 4}$	59.75	2.66	66.25	53.75	1.2
GLD $_{3 \times 3, 3}$	57.19	2.56	64.58	52.92	1.2
GLD $_{3 \times 3, 2}$	60.86	2.42	65.83	55.83	1.2
GLD $_{3 \times 3, 1}$	53.57	2.46	59.17	46.67	1.2
GLD $_{3 \times 3, 0}$	59.75	2.66	66.25	53.75	1.2
HARALICK $_{3 \times 3}$	38.94	2.02	45.00	33.75	195.3
UNSER $_{3 \times 3}$	60.96	1.85	65.42	57.50	54.0

Tabla A.17: Resultados: Outex TC\_00000 y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	97.22	0.89	99.17	95.00	1.4
RANK $_{3 \times 3}$	94.25	1.20	97.50	90.42	1.0




Figura A.6: Texturas de la base de datos Outex\_TC\_00000.

Tabla A.18: Resultados: Outex TC\_00000 y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC1 <sub>3×3</sub>	99.90	0.27	100.00	97.92	1.3
BGC2 <sub>3×3</sub>	99.13	0.51	100.00	97.50	1.3
BGC3 <sub>3×3</sub>	98.83	0.64	100.00	97.50	1.3
BTCS+ <sub>3×3</sub>	89.65	1.64	93.33	85.00	1.2
CCR <sub>3×3</sub>	96.30	1.22	98.75	92.50	1.8
CLBP_M <sub>3×3</sub>	98.11	0.98	100.00	95.83	1.4
CLBP_M/C <sub>3×3</sub>	99.13	0.89	100.00	96.25	1.6
CLBP_S/M <sub>3×3</sub>	99.90	0.23	100.00	99.17	111.6
CLBP_S⊗M/C <sub>3×3</sub>	99.77	0.44	100.00	97.92	2.1
CLBP_S/M/C <sub>3×3</sub>	99.73	0.35	100.00	98.75	240.8
GTUC <sub>3×3,1</sub>	76.07	2.27	81.25	69.17	5.9
GTUC <sub>3×3,2</sub>	83.20	2.10	87.92	78.75	6.1
GTUC <sub>3×3,4</sub>	94.68	1.88	99.17	88.75	6.3
GTUC <sub>3×3,8</sub>	97.47	1.14	99.17	93.33	6.4
GTUC <sub>3×3,16</sub>	97.02	1.30	99.58	93.75	6.2
GTUC <sub>3×3,32</sub>	81.91	2.03	86.67	77.50	5.9
ILBP <sub>3×3</sub>	99.71	0.32	100.00	98.75	1.6
LBP <sub>3×3</sub>	99.68	0.40	100.00	98.33	1.3
LTP <sub>3×3,1</sub>	99.74	0.34	100.00	98.75	1.8
LTP <sub>3×3,2</sub>	99.75	0.42	100.00	98.33	1.8
LTP <sub>3×3,4</sub>	99.65	0.47	100.00	97.50	1.8
LTP <sub>3×3,8</sub>	98.82	0.99	100.00	95.83	1.8
LTP <sub>3×3,16</sub>	98.26	1.02	100.00	95.42	1.7
LTP <sub>3×3,32</sub>	91.43	1.65	95.42	87.92	1.6
MTU16 <sub>3×3</sub>	97.52	0.91	99.17	95.00	1.0
MTU81 <sub>3×3</sub>	98.29	0.79	99.58	96.25	1.1
RTU <sub>3×3</sub>	94.73	1.37	97.92	91.25	2.5
STS <sub>3×3</sub>	98.29	0.79	99.58	96.25	1.1
STU+ <sub>3×3,1</sub>	97.87	1.20	100.00	95.00	1.1
STU+ <sub>3×3,2</sub>	98.16	1.07	100.00	95.00	1.2
STU+ <sub>3×3,4</sub>	98.87	0.90	100.00	96.25	1.2
STU+ <sub>3×3,8</sub>	98.67	0.98	100.00	96.25	1.2
STU+ <sub>3×3,16</sub>	93.55	1.55	96.67	90.00	1.1
STU+ <sub>3×3,32</sub>	74.01	2.55	79.58	67.50	1.2
STU× <sub>3×3,1</sub>	98.92	0.81	100.00	95.83	1.2
STU× <sub>3×3,2</sub>	98.56	0.90	100.00	95.83	1.2
STU× <sub>3×3,4</sub>	99.02	0.88	100.00	96.67	1.2
STU× <sub>3×3,8</sub>	98.27	1.15	100.00	95.00	1.2
STU× <sub>3×3,16</sub>	96.61	1.42	98.75	92.92	1.1
STU× <sub>3×3,32</sub>	85.32	1.94	90.00	79.58	1.1
TU0 <sub>3×3</sub>	99.48	0.40	100.00	98.33	8.7
TUΔ <sub>3×3,1</sub>	99.66	0.49	100.00	97.08	9.0
TUΔ <sub>3×3,2</sub>	99.42	0.53	100.00	97.92	8.8
TUΔ <sub>3×3,4</sub>	99.51	0.56	100.00	97.92	9.0
TUΔ <sub>3×3,8</sub>	99.17	0.65	100.00	97.08	8.6
TUΔ <sub>3×3,16</sub>	98.10	1.07	100.00	95.42	8.9
TUΔ <sub>3×3,32</sub>	89.43	1.69	93.75	85.00	8.5

## A.7. Outex TC\_00001

Tabla A.19: Resultados: Outex TC\_00001 y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	64.04	1.28	68.94	60.98	1.7
GLD $_{3 \times 3, 6}$	65.15	1.13	67.52	61.55	1.7
GLD $_{3 \times 3, 5}$	60.93	1.23	66.10	58.43	1.7
GLD $_{3 \times 3, 4}$	66.61	1.21	69.89	63.83	1.7
GLD $_{3 \times 3, 3}$	64.04	1.28	68.94	60.98	1.7
GLD $_{3 \times 3, 2}$	65.15	1.13	67.52	61.55	1.7
GLD $_{3 \times 3, 1}$	60.93	1.23	66.10	58.43	1.7
GLD $_{3 \times 3, 0}$	66.61	1.21	69.89	63.83	1.7
HARALICK $_{3 \times 3}$	43.82	1.25	46.88	41.10	419.7
UNSER $_{3 \times 3}$	69.04	1.10	72.06	66.76	181.5

Tabla A.20: Resultados: Outex TC\_00001 y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	90.93	0.74	92.80	89.02	1.2
RANK $_{3 \times 3}$	84.36	0.85	86.36	82.67	1.0




Figura A.7: Texturas de la base de datos Outex\_TC\_00001.

Tabla A.21: Resultados: Outex TC\_00001 y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC $1_{3 \times 3}$	98.54	0.32	99.24	97.63	1.7
BGC $2_{3 \times 3}$	96.68	0.50	97.73	95.36	1.6
BGC $3_{3 \times 3}$	96.32	0.47	97.25	95.08	1.7
BTCS $+_{3 \times 3}$	84.05	0.86	86.17	81.91	1.1
CCR $_{3 \times 3}$	91.91	0.65	93.37	90.06	3.6
CLBP $_M_{3 \times 3}$	96.36	0.46	97.63	95.17	1.7
CLBP $_M/C_{3 \times 3}$	98.48	0.31	99.15	97.73	2.4
CLBP $_S/M_{3 \times 3}$	98.03	0.42	98.96	97.16	381.9
CLBP $_S \otimes M/C_{3 \times 3}$	99.28	0.22	99.81	98.67	3.1
CLBP $_S/M/C_{3 \times 3}$	98.06	0.44	99.05	97.06	845.7
GTUC $_{3 \times 3,1}$	61.73	1.02	64.20	58.90	23.2
GTUC $_{3 \times 3,2}$	67.45	1.03	70.27	65.81	22.8
GTUC $_{3 \times 3,4}$	87.34	0.78	88.92	85.70	23.1
GTUC $_{3 \times 3,8}$	95.98	0.47	97.06	94.60	22.7
GTUC $_{3 \times 3,16}$	95.43	0.51	96.50	94.03	22.4
GTUC $_{3 \times 3,32}$	77.61	0.91	79.83	75.57	22.9
ILBP $_{3 \times 3}$	99.41	0.21	99.81	98.86	2.4
LBP $_{3 \times 3}$	98.43	0.28	99.05	97.73	1.7
LTP $_{3 \times 3,1}$	98.73	0.29	99.34	98.11	2.5
LTP $_{3 \times 3,2}$	99.03	0.27	99.62	98.30	2.5
LTP $_{3 \times 3,4}$	99.12	0.27	99.62	98.48	2.4
LTP $_{3 \times 3,8}$	98.90	0.31	99.62	97.92	2.4
LTP $_{3 \times 3,16}$	97.63	0.38	98.58	96.69	2.4
LTP $_{3 \times 3,32}$	86.95	0.84	88.92	84.47	2.4
MTU16 $_{3 \times 3}$	91.35	0.70	92.90	89.20	1.0
MTU81 $_{3 \times 3}$	95.49	0.51	96.97	94.41	1.2
RTU $_{3 \times 3}$	89.58	0.71	91.19	87.97	1.7
STS $_{3 \times 3}$	95.47	0.51	97.06	94.32	1.2
STU $+_{3 \times 3,1}$	95.55	0.46	96.40	94.32	1.2
STU $+_{3 \times 3,2}$	97.17	0.38	98.20	96.40	1.2
STU $+_{3 \times 3,4}$	98.32	0.34	99.05	97.54	1.2
STU $+_{3 \times 3,8}$	98.04	0.43	99.05	96.50	1.2
STU $+_{3 \times 3,16}$	93.56	0.69	94.79	91.67	1.2
STU $+_{3 \times 3,32}$	62.38	1.18	66.38	59.94	2.6
STU $\times_{3 \times 3,1}$	96.64	0.43	97.82	95.64	1.2
STU $\times_{3 \times 3,2}$	97.40	0.37	98.48	96.59	1.2
STU $\times_{3 \times 3,4}$	98.77	0.32	99.62	97.82	1.2
STU $\times_{3 \times 3,8}$	98.33	0.39	99.24	96.78	1.2
STU $\times_{3 \times 3,16}$	96.39	0.55	97.82	94.98	1.2
STU $\times_{3 \times 3,32}$	79.61	0.87	81.63	77.18	1.2
TU $0_{3 \times 3}$	97.79	0.46	98.77	96.59	35.9
TU $\Delta_{3 \times 3,1}$	97.79	0.35	98.86	96.97	35.9
TU $\Delta_{3 \times 3,2}$	98.33	0.29	99.05	97.73	36.1
TU $\Delta_{3 \times 3,4}$	98.94	0.27	99.53	98.20	36.6
TU $\Delta_{3 \times 3,8}$	98.83	0.31	99.62	97.92	38.0
TU $\Delta_{3 \times 3,16}$	97.45	0.42	98.48	96.12	36.4
TU $\Delta_{3 \times 3,32}$	85.07	0.88	87.12	82.95	35.9

## A.8. Outex TC\_00013

Tabla A.22: Resultados: Outex TC\_00013 y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	40.55	1.36	43.53	37.35	1.4
GLD $_{3 \times 3, 6}$	41.29	1.25	44.12	37.50	1.5
GLD $_{3 \times 3, 5}$	39.61	1.49	44.12	36.47	1.4
GLD $_{3 \times 3, 4}$	41.30	1.12	44.26	38.53	1.5
GLD $_{3 \times 3, 3}$	40.55	1.36	43.53	37.35	1.4
GLD $_{3 \times 3, 2}$	41.29	1.25	44.12	37.50	1.4
GLD $_{3 \times 3, 1}$	39.61	1.49	44.12	36.47	1.4
GLD $_{3 \times 3, 0}$	41.30	1.12	44.26	38.53	1.4
HARALICK $_{3 \times 3}$	79.82	1.13	82.65	76.03	285.7
UNSER $_{3 \times 3}$	83.73	1.25	86.32	80.88	106.8

Tabla A.23: Resultados: Outex TC\_00013 y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	71.58	1.07	73.82	69.12	1.3
RANK $_{3 \times 3}$	69.17	1.34	71.91	64.71	1.0




Figura A.8: Texturas de la base de datos Outex\_TC\_00013.

Tabla A.24: Resultados: Outex TC\_00013 y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC $1_{3 \times 3}$	79.09	0.99	81.62	76.62	1.5
BGC $2_{3 \times 3}$	76.81	1.11	79.71	73.97	1.4
BGC $3_{3 \times 3}$	75.93	1.09	79.12	73.24	1.5
BTCS $+_{3 \times 3}$	63.21	1.30	66.62	60.00	1.2
CCR $_{3 \times 3}$	70.73	1.18	73.38	67.79	2.0
CLBP $_M_{3 \times 3}$	72.02	1.30	75.29	68.53	1.5
CLBP $_M/C_{3 \times 3}$	78.24	1.18	81.03	75.29	1.9
CLBP $_S/M_{3 \times 3}$	80.47	1.00	83.53	77.94	216.3
CLBP $_S \otimes M/C_{3 \times 3}$	82.64	1.06	84.71	79.26	2.5
CLBP $_S/M/C_{3 \times 3}$	82.44	1.09	85.15	79.26	468.5
GTUC $_{3 \times 3,1}$	53.13	1.23	56.62	50.44	8.1
GTUC $_{3 \times 3,2}$	68.38	1.33	71.76	63.82	8.3
GTUC $_{3 \times 3,4}$	71.79	1.37	74.56	68.09	8.3
GTUC $_{3 \times 3,8}$	60.60	1.39	64.26	56.03	8.2
GTUC $_{3 \times 3,16}$	38.37	1.32	41.18	34.41	15.0
GTUC $_{3 \times 3,32}$	14.96	0.94	17.94	12.79	90.9
ILBP $_{3 \times 3}$	79.97	0.99	82.21	77.21	1.9
LBP $_{3 \times 3}$	78.18	1.08	80.29	75.29	1.5
LTP $_{3 \times 3,1}$	78.84	1.02	81.18	76.47	2.1
LTP $_{3 \times 3,2}$	80.05	1.18	82.79	76.76	2.1
LTP $_{3 \times 3,4}$	77.61	1.03	80.29	75.15	2.0
LTP $_{3 \times 3,8}$	66.19	1.54	70.59	61.62	2.0
LTP $_{3 \times 3,16}$	43.79	1.30	46.32	38.82	8.8
LTP $_{3 \times 3,32}$	19.60	0.96	22.06	17.21	84.3
MTU16 $_{3 \times 3}$	69.88	1.18	72.35	67.50	1.0
MTU81 $_{3 \times 3}$	74.53	1.23	77.50	72.06	1.2
RTU $_{3 \times 3}$	72.77	1.16	75.59	70.15	2.2
STS $_{3 \times 3}$	74.51	1.24	77.50	71.91	1.2
STU $+_{3 \times 3,1}$	77.12	1.08	79.85	75.15	1.2
STU $+_{3 \times 3,2}$	77.47	1.13	80.00	74.85	1.2
STU $+_{3 \times 3,4}$	70.39	1.35	73.24	66.76	1.2
STU $+_{3 \times 3,8}$	53.51	1.29	56.91	50.59	1.6
STU $+_{3 \times 3,16}$	31.25	1.15	34.26	27.50	36.6
STU $+_{3 \times 3,32}$	12.65	0.83	16.18	11.03	136.1
STU $\times_{3 \times 3,1}$	79.70	1.07	82.65	77.06	1.2
STU $\times_{3 \times 3,2}$	79.20	1.10	82.35	77.06	1.2
STU $\times_{3 \times 3,4}$	75.80	1.09	78.38	72.94	1.2
STU $\times_{3 \times 3,8}$	59.88	1.52	63.24	56.03	1.2
STU $\times_{3 \times 3,16}$	37.81	1.34	41.18	34.41	10.7
STU $\times_{3 \times 3,32}$	16.90	0.98	19.26	14.12	90.7
TU $0_{3 \times 3}$	79.32	1.00	82.21	76.76	12.0
TU $\Delta_{3 \times 3,1}$	80.39	1.06	82.79	77.50	12.2
TU $\Delta_{3 \times 3,2}$	79.86	1.01	82.50	77.21	12.1
TU $\Delta_{3 \times 3,4}$	77.07	1.06	79.41	74.12	12.1
TU $\Delta_{3 \times 3,8}$	62.59	1.50	66.62	59.12	12.0
TU $\Delta_{3 \times 3,16}$	40.81	1.34	43.38	36.47	21.4
TU $\Delta_{3 \times 3,32}$	18.41	0.95	20.74	15.29	100.0



## A.9. UIUCtex

Tabla A.25: Resultados: UIUCTex y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	34.40	1.68	37.80	30.00	1.0
GLD $_{3 \times 3, 6}$	32.66	1.74	37.80	29.00	1.0
GLD $_{3 \times 3, 5}$	33.07	1.81	38.20	28.80	1.0
GLD $_{3 \times 3, 4}$	33.52	1.64	37.60	29.40	1.0
GLD $_{3 \times 3, 3}$	34.40	1.68	37.80	30.00	1.0
GLD $_{3 \times 3, 2}$	32.66	1.74	37.80	29.00	1.0
GLD $_{3 \times 3, 1}$	33.07	1.81	38.20	28.80	1.0
GLD $_{3 \times 3, 0}$	33.52	1.64	37.60	29.40	1.0
HARALICK $_{3 \times 3}$	46.02	1.61	50.60	42.60	102.2
UNSER $_{3 \times 3}$	68.09	1.66	72.40	64.40	18.0

Tabla A.26: Resultados: UIUCTex y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	44.23	1.84	48.20	39.80	1.5
RANK $_{3 \times 3}$	57.05	1.73	61.80	53.00	1.2




Figura A.9: Texturas de la base de datos UIUCTex.

Tabla A.27: Resultados: UIUCTex y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC1 <sub>3×3</sub>	58.66	1.76	63.00	53.40	1.6
BGC2 <sub>3×3</sub>	52.37	1.84	57.80	48.40	1.5
BGC3 <sub>3×3</sub>	52.47	1.89	57.00	48.40	1.5
BTCS+ <sub>3×3</sub>	41.21	1.95	47.00	35.20	1.5
CCR <sub>3×3</sub>	53.07	1.77	57.80	48.40	2.2
CLBP_M <sub>3×3</sub>	53.54	1.73	58.00	49.00	1.6
CLBP_M/C <sub>3×3</sub>	68.42	1.75	73.60	64.60	1.9
CLBP_S/M <sub>3×3</sub>	75.66	1.89	80.80	72.00	39.4
CLBP_S⊗M/C <sub>3×3</sub>	72.83	1.72	76.60	69.00	2.9
CLBP_S/M/C <sub>3×3</sub>	81.92	1.42	85.60	77.80	85.2
GTUC <sub>3×3,1</sub>	28.08	1.60	32.00	24.00	4.6
GTUC <sub>3×3,2</sub>	39.37	1.64	44.40	35.00	4.8
GTUC <sub>3×3,4</sub>	47.45	1.69	51.40	43.80	5.2
GTUC <sub>3×3,8</sub>	53.42	1.67	56.80	49.20	5.4
GTUC <sub>3×3,16</sub>	51.25	1.97	56.00	46.80	5.2
GTUC <sub>3×3,32</sub>	40.31	1.69	44.40	36.60	4.7
ILBP <sub>3×3</sub>	62.51	1.91	67.60	58.20	1.9
LBP <sub>3×3</sub>	57.25	1.80	61.80	53.60	1.5
LTP <sub>3×3,1</sub>	57.31	1.90	62.60	53.60	2.6
LTP <sub>3×3,2</sub>	59.07	1.92	64.80	54.40	2.6
LTP <sub>3×3,4</sub>	61.87	1.77	66.00	58.00	2.6
LTP <sub>3×3,8</sub>	63.34	1.75	68.80	59.20	2.5
LTP <sub>3×3,16</sub>	59.23	1.87	64.20	54.80	2.5
LTP <sub>3×3,32</sub>	49.08	1.86	54.00	45.60	2.4
MTU16 <sub>3×3</sub>	44.30	1.92	49.00	40.60	1.1
MTU81 <sub>3×3</sub>	49.26	1.80	54.40	44.40	1.5
RTU <sub>3×3</sub>	62.97	1.76	67.80	58.60	4.1
STS <sub>3×3</sub>	49.26	1.80	54.40	44.40	1.5
STU+ <sub>3×3,1</sub>	57.03	1.66	61.60	52.80	1.5
STU+ <sub>3×3,2</sub>	59.01	1.67	64.20	53.80	1.5
STU+ <sub>3×3,4</sub>	62.11	1.70	67.20	57.80	1.5
STU+ <sub>3×3,8</sub>	58.89	1.91	63.60	54.40	1.5
STU+ <sub>3×3,16</sub>	48.07	1.90	52.60	42.80	1.5
STU+ <sub>3×3,32</sub>	34.85	1.62	39.60	30.20	1.5
STU× <sub>3×3,1</sub>	57.57	1.82	64.00	54.00	1.5
STU× <sub>3×3,2</sub>	60.96	1.81	65.40	56.20	1.5
STU× <sub>3×3,4</sub>	64.72	1.81	70.40	60.80	1.5
STU× <sub>3×3,8</sub>	65.06	1.78	70.20	61.40	1.5
STU× <sub>3×3,16</sub>	56.38	1.70	61.00	53.40	1.5
STU× <sub>3×3,32</sub>	41.48	1.85	45.60	36.60	1.5
TU0 <sub>3×3</sub>	63.02	1.69	66.80	58.40	4.2
TUΔ <sub>3×3,1</sub>	63.95	1.79	68.40	59.00	4.2
TUΔ <sub>3×3,2</sub>	66.04	1.67	70.00	62.00	4.2
TUΔ <sub>3×3,4</sub>	68.66	1.62	72.40	63.80	4.2
TUΔ <sub>3×3,8</sub>	67.75	1.77	72.40	63.40	4.2
TUΔ <sub>3×3,16</sub>	61.30	1.88	67.40	56.60	4.2
TUΔ <sub>3×3,32</sub>	49.37	1.88	54.40	46.00	4.1

## A.10. VisTex

Tabla A.28: Resultados: Vistex y marginalización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLD $_{3 \times 3, 7}$	50.95	1.03	53.67	47.98	1.6
GLD $_{3 \times 3, 6}$	52.16	0.96	54.49	49.93	1.6
GLD $_{3 \times 3, 5}$	49.11	0.96	52.02	47.16	1.6
GLD $_{3 \times 3, 4}$	53.09	0.99	55.84	50.97	1.6
GLD $_{3 \times 3, 3}$	50.95	1.03	53.67	47.98	1.6
GLD $_{3 \times 3, 2}$	52.16	0.96	54.49	49.93	1.6
GLD $_{3 \times 3, 1}$	49.11	0.96	52.02	47.16	1.6
GLD $_{3 \times 3, 0}$	53.09	0.99	55.84	50.97	1.6
HARALICK $_{3 \times 3}$	77.66	0.79	79.94	75.45	435.5
UNSER $_{3 \times 3}$	71.43	0.84	73.35	69.46	190.5

Tabla A.29: Resultados: Vistex y ordenación.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
GLTCS $_{+3 \times 3}$	58.31	0.97	60.40	54.72	1.2
RANK $_{3 \times 3}$	54.11	0.95	56.74	51.95	1.0




Figura A.10: Texturas de la base de datos VisTex.

Tabla A.30: Resultados: Vistex y umbralización.

Descriptores	$t_\mu$	$t_\sigma$	$t_{\text{máx}}$	$t_{\text{mín}}$	$T$
BGC $1_{3 \times 3}$	76.19	0.84	77.99	73.43	1.7
BGC $2_{3 \times 3}$	69.87	0.82	71.41	67.37	1.6
BGC $3_{3 \times 3}$	68.51	1.00	71.03	65.94	1.6
BTCS $+_{3 \times 3}$	41.16	0.98	44.01	38.35	1.1
CCR $_{3 \times 3}$	53.37	1.04	55.54	50.90	2.4
CLBP $_M_{3 \times 3}$	66.06	1.05	68.64	62.20	1.7
CLBP $_M/C_{3 \times 3}$	67.80	0.87	70.06	66.17	2.3
CLBP $_S/M_{3 \times 3}$	75.79	0.86	77.99	73.95	387.8
CLBP $_S \otimes M/C_{3 \times 3}$	75.87	0.92	77.77	74.03	3.1
CLBP $_S/M/C_{3 \times 3}$	74.86	0.94	77.10	72.90	816.5
GTUC $_{3 \times 3,1}$	38.29	1.05	40.64	35.63	11.8
GTUC $_{3 \times 3,2}$	51.26	1.00	53.59	48.20	11.9
GTUC $_{3 \times 3,4}$	61.83	1.00	63.92	59.13	11.9
GTUC $_{3 \times 3,8}$	65.71	0.95	67.89	63.40	12.0
GTUC $_{3 \times 3,16}$	61.98	1.08	64.90	59.28	11.9
GTUC $_{3 \times 3,32}$	53.37	0.84	55.76	50.82	12.2
ILBP $_{3 \times 3}$	77.15	0.79	79.04	75.15	2.4
LBP $_{3 \times 3}$	74.20	0.82	76.05	72.38	1.7
LTP $_{3 \times 3,1}$	75.10	0.83	77.10	72.83	2.5
LTP $_{3 \times 3,2}$	76.46	0.93	78.29	73.80	2.5
LTP $_{3 \times 3,4}$	75.39	0.87	77.40	73.65	2.5
LTP $_{3 \times 3,8}$	71.42	0.85	74.10	69.46	2.5
LTP $_{3 \times 3,16}$	65.67	0.94	68.26	63.70	2.4
LTP $_{3 \times 3,32}$	56.38	0.77	58.23	54.34	2.8
MTU16 $_{3 \times 3}$	56.64	0.96	59.13	54.57	1.0
MTU81 $_{3 \times 3}$	66.34	0.98	68.26	64.52	1.2
RTU $_{3 \times 3}$	64.76	0.85	66.84	62.57	1.9
STS $_{3 \times 3}$	66.33	0.98	68.26	64.45	1.2
STU $+_{3 \times 3,1}$	72.24	0.88	74.18	69.76	1.2
STU $+_{3 \times 3,2}$	73.35	0.86	75.52	71.18	1.2
STU $+_{3 \times 3,4}$	72.67	0.83	74.55	69.99	1.2
STU $+_{3 \times 3,8}$	68.69	0.96	71.03	66.32	1.2
STU $+_{3 \times 3,16}$	60.27	0.87	62.13	58.01	1.2
STU $+_{3 \times 3,32}$	47.00	0.95	49.03	45.21	3.4
STU $\times_{3 \times 3,1}$	72.03	0.93	74.03	69.76	1.2
STU $\times_{3 \times 3,2}$	72.78	1.00	75.15	69.99	1.2
STU $\times_{3 \times 3,4}$	72.67	0.93	75.37	69.84	1.2
STU $\times_{3 \times 3,8}$	69.42	1.09	72.53	67.37	1.2
STU $\times_{3 \times 3,16}$	63.65	1.02	65.94	61.68	1.2
STU $\times_{3 \times 3,32}$	52.84	0.97	55.84	49.93	1.7
TU $0_{3 \times 3}$	76.49	0.92	78.89	74.33	21.7
TU $\Delta_{3 \times 3,1}$	78.46	0.86	80.24	76.20	21.2
TU $\Delta_{3 \times 3,2}$	78.78	0.81	80.61	76.35	21.8
TU $\Delta_{3 \times 3,4}$	77.40	0.74	78.74	75.00	20.8
TU $\Delta_{3 \times 3,8}$	73.95	0.91	76.12	71.33	21.6
TU $\Delta_{3 \times 3,16}$	67.69	1.01	70.21	65.64	20.9
TU $\Delta_{3 \times 3,32}$	57.67	0.94	59.81	54.42	22.4



## Apéndice B

# Implementación en Matlab

```
function [h, varargout] = histoTP3x3(I, mapping, varargin)
%
% This function computes the histogram of 3x3 texture patterns of a
% single channel texture image quantized to G=256 gray levels. Texture
% patterns are binned according to the rule defined by "mapping". The
% function can also return a matrix with the texture pattern codes.
%
% [h, varargout] = histoTP3x3(I, mapping, varargin)
%
% Input:
%   I       - Single channel texture image (at least 3x3 pixels)
%   mapping - Pattern mapping
%
% Optional input:
%   Mapping parameters
%
% Output:
%   h       - Histogram of equivalent patterns
%
% Optional input:
%   k       - Texture codes
%   q       - Dimension of the feature space
%   lims    - Coordinates of the image region inside of which valid
%             texture codes can be computed. The coordinates are
%             arranged as follows:
%             [first_row, last_row, first_column, last_column]
%
% Last modified: 1 March 2011

% Optional arguments
optargin = size(varargin,2);

% Number of gray levels
G = 256;

% Image size: M rows and N columns
[M N] = size(I);
```

```

% Conversion to avoid errors when using sort, unique...
I = double(I);

% Define shifted images
[I7, I6, I5, I4, I3, I2, I1, I0] = deal(zeros(size(I)));
I7(2:M, 2:N) = I(1:M-1,1:N-1);
I6(2:M, 1:N) = I(1:M-1,1:N );
I5(2:M, 1:N-1) = I(1:M-1,2:N );
I4(1:M, 1:N-1) = I(1:M, 2:N );
I3(1:M-1,1:N-1) = I(2:M, 2:N );
I2(1:M-1,1:N) = I(2:M, 1:N );
I1(1:M-1,2:N) = I(2:M, 1:N-1);
I0(1:M, 2:N) = I(1:M, 1:N-1);

% Pre-defined lims
first_row = 2;
last_row = M-1;
first_column = 2;
last_column = N-1;

switch mapping

    % MARGINALIZATION BASED MAPPINGS

    case 'C00C2_3x3'
        if(optargin==1)
            q = G^2; % 256^2=65536
            Ij_str = strcat('I',num2str(varargin{1}));
            k0 = G*I + eval(Ij_str);
            first_row = 1;
            last_row = M;
            first_column = 1;
            last_column = N;
            if ismember(varargin{1},[7 6 5])>0;
                first_row = 2;
            end
            if ismember(varargin{1},[1 2 3])>0;
                last_row = M-1;
            end
            if ismember(varargin{1},[7 0 1])>0;
                first_column = 2;
            end
            if ismember(varargin{1},[5 4 3])>0;
                last_column = N-1;
            end
            k = k0(first_row:last_row, first_column:last_column);
            % Compute and normalize the histogram
            h = sum(hist(k,0:q-1),2)' / numel(k);
        else
            error('The function C00C2_3x3 requires 3 input parameters')
        end

    case 'C00C3_3x3'

```

---

```

if(optargin==2)
    q = G^3; % 16777216
    Ij1_str = strcat('I',num2str(varargin{1}));
    Ij2_str = strcat('I',num2str(varargin{2}));
    k0 = G*G*I + G*eval(Ij1_str) + eval(Ij2_str);
    first_row = 1;
    last_row = M;
    first_column = 1;
    last_column = N;
    argins = [varargin{1} varargin{2}];
    if sum(ismember(argins,[7 6 5]))>0;
        first_row = 2;
    end
    if sum(ismember(argins,[1 2 3]))>0;
        last_row = M-1;
    end
    if sum(ismember(argins,[7 0 1]))>0;
        first_column = 2;
    end
    if sum(ismember(argins,[5 4 3]))>0;
        last_column = N-1;
    end
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);
else
    error('The function COOC3_3x3 requires 4 input parameters')
end

case 'DH_3x3'
if(optargin==1)
    q = 2*G-1; % 2*256-1=511
    Ij_str = strcat('I',num2str(varargin{1}));
    k0 = I - eval(Ij_str) + G - 1;
    first_row = 1;
    last_row = M;
    first_column = 1;
    last_column = N;
    if ismember(varargin{1},[7 6 5])>0;
        first_row = 2;
    end
    if ismember(varargin{1},[1 2 3])>0;
        last_row = M-1;
    end
    if ismember(varargin{1},[7 0 1])>0;
        first_column = 2;
    end
    if ismember(varargin{1},[5 4 3])>0;
        last_column = N-1;
    end
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);
else

```



```

        error('The function DH_3x3 requires 3 input parameters')
    end

case 'GLD_3x3'
    if(optargin==1)
        q = G; % 256
        Ij_str = strcat('I',num2str(varargin{1}));
        k0 = abs(I-eval(Ij_str));
        first_row = 1;
        last_row = M;
        first_column = 1;
        last_column = N;
        if ismember(varargin{1},[7 6 5])>0;
            first_row = 2;
        end
        if ismember(varargin{1},[1 2 3])>0;
            last_row = M-1;
        end
        if ismember(varargin{1},[7 0 1])>0;
            first_column = 2;
        end
        if ismember(varargin{1},[5 4 3])>0;
            last_column = N-1;
        end
        k = k0(first_row:last_row, first_column:last_column);
        % Compute and normalize the histogram
        h = sum(hist(k,0:q-1),2)' / numel(k);
    else
        error('The function GLD_3x3 requires 3 input parameters')
    end

case 'HARALICK_3x3'
    q = G^2; % 256^2=65536

    k60 = G*I + I6;
    k40 = G*I + I4;
    k20 = G*I + I2;
    k00 = G*I + I0;

    k6 = k60(first_row:last_row, first_column:last_column);
    k4 = k40(first_row:last_row, first_column:last_column);
    k2 = k20(first_row:last_row, first_column:last_column);
    k0 = k00(first_row:last_row, first_column:last_column);

    % Compute and normalize the histograms
    h6 = sum(hist(k6,0:q-1),2)' / numel(k6);
    h4 = sum(hist(k4,0:q-1),2)' / numel(k4);
    h2 = sum(hist(k2,0:q-1),2)' / numel(k2);
    h0 = sum(hist(k0,0:q-1),2)' / numel(k0);

    % The codes returned by the function correspond to displacement
    % vector (1,0)
    k = k4;
    % Average of histograms corresponding to displacements (0,1),

```

```

% (1,0), (0,-1) and (-1,0)
h = (h6+h4+h2+h0)/4;

case 'SDH_3x3'
if(optargin==1)
    q = 2*(2*G-1); % 2*(2*256-1)=1022
    Ij_str = strcat('I',num2str(varargin{1}));
    ks0 = I + eval(Ij_str);
    kd0 = I - eval(Ij_str) + G - 1;
    first_row = 1;
    last_row = M;
    first_column = 1;
    last_column = N;
    if ismember(varargin{1},[7 6 5])>0;
        first_row = 2;
    end
    if ismember(varargin{1},[1 2 3])>0;
        last_row = M-1;
    end
    if ismember(varargin{1},[7 0 1])>0;
        first_column = 2;
    end
    if ismember(varargin{1},[5 4 3])>0;
        last_column = N-1;
    end
    ks = ks0(first_row:last_row, first_column:last_column);
    kd = kd0(first_row:last_row, first_column:last_column);
    % Define a different code for each combination of sum and
    % difference codes
    k = ks + kd*q/2;
    % Compute and normalize the histogram
    hs = sum(hist(ks,0:q-1),2)' / numel(ks);
    hd = sum(hist(kd,0:q-1),2)' / numel(kd);
    h = [hd hs];
else
    error('The function SDH_3x3 requires 3 input parameters')
end

case 'SH_3x3'
if(optargin==1)
    q = 2*G-1; % 2*256-1=511
    Ij_str = strcat('I',num2str(varargin{1}));
    k0 = I + eval(Ij_str);
    first_row = 1;
    last_row = M;
    first_column = 1;
    last_column = N;
    if ismember(varargin{1},[7 6 5])>0;
        first_row = 2;
    end
    if ismember(varargin{1},[1 2 3])>0;
        last_row = M-1;
    end
    if ismember(varargin{1},[7 0 1])>0;

```

```

        first_column = 2;
    end
    if ismember(varargin{1},[5 4 3])>0;
        last_column = N-1;
    end
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);
else
    error('The function SH_3x3 requires 3 input parameters')
end

case 'UNSER_3x3'
    q = 4*2*(2*G-1); % 4*2*(2*256-1)=4088

    k60d = I - I6 + G - 1;
    k40d = I - I4 + G - 1;
    k20d = I - I2 + G - 1;
    k00d = I - I0 + G - 1;
    k60s = I + I6;
    k40s = I + I4;
    k20s = I + I2;
    k00s = I + I0;

    k6s = k60s(first_row:last_row, first_column:last_column);
    k4s = k40s(first_row:last_row, first_column:last_column);
    k2s = k20s(first_row:last_row, first_column:last_column);
    k0s = k00s(first_row:last_row, first_column:last_column);
    k6d = k60d(first_row:last_row, first_column:last_column);
    k4d = k40d(first_row:last_row, first_column:last_column);
    k2d = k20d(first_row:last_row, first_column:last_column);
    k0d = k00d(first_row:last_row, first_column:last_column);

    % Compute and normalize the histograms
    h6s = sum(hist(k6s,0:q-1),2)' / numel(k6s);
    h4s = sum(hist(k4s,0:q-1),2)' / numel(k4s);
    h2s = sum(hist(k2s,0:q-1),2)' / numel(k2s);
    h0s = sum(hist(k0s,0:q-1),2)' / numel(k0s);
    h6d = sum(hist(k6d,0:q-1),2)' / numel(k6d);
    h4d = sum(hist(k4d,0:q-1),2)' / numel(k4d);
    h2d = sum(hist(k2d,0:q-1),2)' / numel(k2d);
    h0d = sum(hist(k0d,0:q-1),2)' / numel(k0d);

    % Define a different code for each combination of sum and
    % difference codes corresponding to displacement vector (1,0)
    k = k4s + k4d*q/8;
    % Concatenate the sum-difference histograms corresponding to
    % displacement vectors (0,1), (1,0), (0,-1) and (-1,0)
    h = [h6s h4s h2s h0s h6d h4d h2d h0d];

% THRESHOLDING BASED MAPPINGS

case 'BGC1_3x3'
    q = 2^8-1; % 255

```

---

```

k0 = 128*(I7>=I0) + 64*(I6>=I7) + 32*(I5>=I6) + ...
      16*(I4>=I5) + 8*(I3>=I4) + 4*(I2>=I3) + ...
      2*(I1>=I2) + (I0>=I1) - 1;
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'BGC2_3x3'
q = (2^4-1)^2; % 225
k0 = 15 * (8*(I6>=I0) + 4*(I4>=I6) + 2*(I2>=I4) + ...
          (I0>=I2)) + 8*(I7>=I1) + 4*(I5>=I7) + ...
          2*(I3>=I5) + (I1>=I3) - 16;
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'BGC3_3x3'
q = 2^8-1; % 255
k0 = 128*(I5>=I0) + 64*(I2>=I5) + 32*(I7>=I2) + ...
      16*(I4>=I7) + 8*(I1>=I4) + 4*(I6>=I1) + ...
      2*(I3>=I6) + (I0>=I3) - 1;
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'BTCS+_3x3'
q = 2^4; % 16
% Compute isoentropic threshold T
H = sum(hist(double(I),0:G-1),2);
H = H/sum(H);
entropy = cumsum(-H.*log2(H+(H==0)));
T = sum( (entropy/entropy(end)) <= 0.5 ) - 1;
k0 = 8*(I6>=T) + 4*(I4>=T) + 2*(I2>=T) + (I0>=T);
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'CCR_3x3'
q = 2^9; % 512
% Compute isoentropic threshold T
H = sum(hist(double(I),0:G-1),2);
H = H/sum(H);
entropy = cumsum(-H.*log2(H+(H==0)));
T = sum( (entropy/entropy(end)) <= 0.5 ) - 1;
k0 = 256*(I>=T) + ...
      128*(I7>=T) + 64*(I6>=T) + 32*(I5>=T) + 16*(I4>=T) + ...
      8*(I3>=T) + 4*(I2>=T) + 2*(I1>=T) + (I0>=T);
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'CLBP_M_3x3'
q = 2^8; % 256
% Compute mean magnitude

```

```

m = mean2(abs(I7-I)+abs(I6-I)+abs(I5-I)+abs(I4-I)+ ...
          abs(I3-I)+abs(I2-I)+abs(I1-I)+abs(I0-I))/8;

k0 = 128*(abs(I7-I)>=m) + 64*(abs(I6-I)>=m) + ...
     32*(abs(I5-I)>=m) + 16*(abs(I4-I)>=m) + ...
     8*(abs(I3-I)>=m) + 4*(abs(I2-I)>=m) + ...
     2*(abs(I1-I)>=m) + (abs(I0-I)>=m);
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'CLBP_MxC_3x3'
q = 2*(2^8); % 512
% Compute mean magnitude
m = mean2(abs(I7-I)+abs(I6-I)+abs(I5-I)+abs(I4-I)+ ...
          abs(I3-I)+abs(I2-I)+abs(I1-I)+abs(I0-I))/8;
% Compute mean for center pixels
c = mean2(I);

kc = (I>=c);
km = 128*(abs(I7-I)>=m) + 64*(abs(I6-I)>=m) + ...
     32*(abs(I5-I)>=m) + 16*(abs(I4-I)>=m) + ...
     8*(abs(I3-I)>=m) + 4*(abs(I2-I)>=m) + ...
     2*(abs(I1-I)>=m) + (abs(I0-I)>=m);
k0 = kc*q/2 + km;
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'CLBP_SxM_3x3'
q = (2^8)^2; % 65536
% Compute mean magnitude
m = mean2(abs(I7-I)+abs(I6-I)+abs(I5-I)+abs(I4-I)+ ...
          abs(I3-I)+abs(I2-I)+abs(I1-I)+abs(I0-I))/8;

ks = 128*(I7>=I) + 64*(I6>=I) + 32*(I5>=I) + 16*(I4>=I) + ...
     8*(I3>=I) + 4*(I2>=I) + 2*(I1>=I) + (I0>=I);
km = 128*(abs(I7-I)>=m) + 64*(abs(I6-I)>=m) + ...
     32*(abs(I5-I)>=m) + 16*(abs(I4-I)>=m) + ...
     8*(abs(I3-I)>=m) + 4*(abs(I2-I)>=m) + ...
     2*(abs(I1-I)>=m) + (abs(I0-I)>=m);
k0 = ks*sqrt(q) + km;
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k,0:q-1),2)' / numel(k);

case 'CLBP_S_MxC_3x3'
qs = 2^8; % 256
qmc = 2*(2^8); % 512
q = qs + qmc; % 768
% Compute mean magnitude
m = mean2(abs(I7-I)+abs(I6-I)+abs(I5-I)+abs(I4-I)+ ...
          abs(I3-I)+abs(I2-I)+abs(I1-I)+abs(I0-I))/8;
% Compute mean for center pixels

```

```

c = mean2(I);

k0s = 128*(I7>=I) + 64*(I6>=I) + 32*(I5>=I) + 16*(I4>=I) + ...
      8*(I3>=I) + 4*(I2>=I) + 2*(I1>=I) + (I0>=I);
kc = (I>=c);
km = 128*(abs(I7-I)>=m) + 64*(abs(I6-I)>=m) + ...
      32*(abs(I5-I)>=m) + 16*(abs(I4-I)>=m) + ...
      8*(abs(I3-I)>=m) + 4*(abs(I2-I)>=m) + ...
      2*(abs(I1-I)>=m) + (abs(I0-I)>=m);
k0mc = kc*qmc/2 + km;
ks = k0s(first_row:last_row, first_column:last_column);
kmc = k0mc(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
hs = sum(hist(ks, 0:qs-1), 2)' / numel(ks);
hmc = sum(hist(kmc, 0:qmc-1), 2)' / numel(kmc);

k = ks * qmc + kmc;
% Concatenate the histograms
h = [hs hmc];

case 'CLBP_SxMxC_3x3'
q = 2*(2^8)^2; % 131072
% Compute mean magnitude
m = mean2(abs(I7-I)+abs(I6-I)+abs(I5-I)+abs(I4-I)+ ...
          abs(I3-I)+abs(I2-I)+abs(I1-I)+abs(I0-I))/8;
% Compute mean for center pixels
c = mean2(I);

kc = (I>=c);
ks = 128*(I7>=I) + 64*(I6>=I) + 32*(I5>=I) + 16*(I4>=I) + ...
      8*(I3>=I) + 4*(I2>=I) + 2*(I1>=I) + (I0>=I);
km = 128*(abs(I7-I)>=m) + 64*(abs(I6-I)>=m) + ...
      32*(abs(I5-I)>=m) + 16*(abs(I4-I)>=m) + ...
      8*(abs(I3-I)>=m) + 4*(abs(I2-I)>=m) + ...
      2*(abs(I1-I)>=m) + (abs(I0-I)>=m);
k0 = 256*256*kc + 256*ks + km;
k = k0(first_row:last_row, first_column:last_column);
% Compute and normalize the histogram
h = sum(hist(k, 0:q-1), 2)' / numel(k);

case 'GTUC_3x3'
q = 2*3^7; %4374
if(optargin==1)
D = varargin{1};
% vartheta(x,x,D) can only take values of either 0 or 2
k0 = 2187*(vartheta(I7-I, I7-I, D)>0) + ...
      729* vartheta(I6-I, I7-I, D) + ...
      243* vartheta(I5-I, I7-I, D) + ...
      81* vartheta(I4-I, I7-I, D) + ...
      27* vartheta(I3-I, I7-I, D) + ...
      9* vartheta(I2-I, I7-I, D) + ...
      3* vartheta(I1-I, I7-I, D) + ...
      vartheta(I0-I, I7-I, D);
k = k0(first_row:last_row, first_column:last_column);

```

```

        % Compute and normalize the histogram
        h = sum(hist(k,0:q-1),2)' / numel(k);
    else
        error('The function GTUC_3x3 requires 3 input parameters')
    end

case 'ILBP_3x3'
    q = 2^9-1; % 511
    % Averaging mask
    mask = ones(3,3)/9;
    % Local mean
    Iav = conv2(I,mask,'same');
    k0 = 256*(I>=Iav) + ...
        128*(I7>=I) + 64*(I6>=I) + 32*(I5>=I) + 16*(I4>=I) + ...
        8*(I3>=I) + 4*(I2>=I) + 2*(I1>=I) + (I0>=I) - 1;
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'LBP_3x3'
    q = 2^8; % 256
    k0 = 128*(I7>=I) + 64*(I6>=I) + 32*(I5>=I) + 16*(I4>=I) + ...
        8*(I3>=I) + 4*(I2>=I) + 2*(I1>=I) + (I0>=I);
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'LTP_3x3'
    qu = 2^8;
    ql = 2^8;
    q = qu + ql; % 512
    if(optargin==1)
        D = varargin{1};
        k0u = 128*(I7>=I+D) + 64*(I6>=I+D) + 32*(I5>=I+D) + ...
            16*(I4>=I+D) + 8*(I3>=I+D) + 4*(I2>=I+D) + ...
            2*(I1>=I+D) + (I0>=I+D);
        k0l = 128*(I7<=I-D) + 64*(I6<=I-D) + 32*(I5<=I-D) + ...
            16*(I4<=I-D) + 8*(I3<=I-D) + 4*(I2<=I-D) + ...
            2*(I1<=I-D) + (I0<=I-D);
        ku = k0u(first_row:last_row, first_column:last_column);
        kl = k0l(first_row:last_row, first_column:last_column);
        k = ku * ql + kl;
        % Compute, normalize and concatenate the histograms
        hu = sum(hist(ku,0:qu-1),2)' / numel(ku);
        hl = sum(hist(kl,0:ql-1),2)' / numel(kl);
        h = [hu hl];
    else
        error('The function LTP_3x3 requires 3 input parameters')
    end

case 'MTU16_3x3'
    q = 2^4; % 16
    last_row = M;
    k0 = 8*(I>=I7)+ 4*(I>=I6) + 2*(I>=I5) + (I>=I4);

```

---

```

    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'MTU81_3x3'
    q = 3^4; % 81
    last_row = M;
    k0 = 27*eta(I-I7,0)+ 9*eta(I-I6,0) + 3*eta(I-I5,0) + ...
        eta(I-I4,0);
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'RTU_3x3'
    q = 45;
    [alpha0, alpha1] = deal(zeros(size(I)));
    for j=0:7;
        Ij_str = strcat('I',num2str(j));
        alpha0 = alpha0 + eval(['eta(', Ij_str, '-I,0)==0;']);
        alpha1 = alpha1 + eval(['eta(', Ij_str, '-I,0)==1;']);
    end
    sum0_n0_8_n0 = [0, 9, 17, 24, 30, 35, 39, 42, 44];
    k0 = sum0_n0_8_n0(alpha0+1) + alpha1;
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'STS_3x3'
    q = 3^4; %81
    last_row = M;
    k0 = 27*eta(I7-I,0) + 9*eta(I6-I,0) + 3*eta(I5-I,0) + ...
        eta(I4-I,0);
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'STU+_3x3'
    q = 3^4; % 81
    if(optargin==1)
        D = varargin{1};
        k0 = 27*eta(I6-I,D) + 9*eta(I4-I,D) + ...
            3*eta(I2-I,D) + eta(I0-I,D);
        k = k0(first_row:last_row, first_column:last_column);
        % Compute and normalize the histogram
        h = sum(hist(k,0:q-1),2)' / numel(k);
    else
        error('The function STUx_3x3 requires 3 input parameters')
    end

case 'STUx_3x3'
    q = 3^4; % 81
    if(optargin==1)
        D = varargin{1};
        k0 = 27*eta(I7-I,D) + 9*eta(I5-I,D) + ...

```



```

        3*eta(I3-I,D) + eta(I1-I,D);
        k = k0(first_row:last_row, first_column:last_column);
        % Compute and normalize the histogram
        h = sum(hist(k,0:q-1),2)' / numel(k);
    else
        error('The function STUx_3x3 requires 3 input parameters')
    end

case 'TU0_3x3'
    q = 3^8; %6561
    k0 = 2187*eta(I7-I,0) + 729*eta(I6-I,0) + 243*eta(I5-I,0) + ...
        81*eta(I4-I,0) + 27*eta(I3-I,0) + 9*eta(I2-I,0) + ...
        3*eta(I1-I,0) + eta(I0-I,0);
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'TUDelta_3x3'
    q = 3^8; %6561
    if(optargin==1)
        D = varargin{1};
        k0 = 2187*eta(I7-I,D) + 729*eta(I6-I,D) + ...
            243*eta(I5-I,D) + 81*eta(I4-I,D) + ...
            27*eta(I3-I,D) + 9*eta(I2-I,D) + ...
            3*eta(I1-I,D) + eta(I0-I,D);
        k = k0(first_row:last_row, first_column:last_column);
        % Compute and normalize the histogram
        h = sum(hist(k,0:q-1),2)' / numel(k);
    else
        error('The function TUDelta_3x3 requires 3 input parameters')
    end

% RANKING BASED MAPPINGS

case 'GLTCS+_3x3'
    q = factorial(4); % 24
    k0 = zeros(size(I));
    I3D = zeros(size(I,1),size(I,2),4);
    for j=1:4;
        I3D(:,:,j) = eval(strcat('I',num2str(2*(j-1))));
    end
    for j=2:4;
        k0 = k0 + sum(repmat(squeeze(I3D(:,:,j)),...
            [1,1,j-1])>=I3D(:,:,1:j-1),3)*factorial(j-1);
    end
    k = k0(first_row:last_row, first_column:last_column);
    % Compute and normalize the histogram
    h = sum(hist(k,0:q-1),2)' / numel(k);

case 'RANK_3x3'
    q = 9;
    k0 = ((I>I7) + (I>I6) + (I>I5) + (I>I4) + ...
        (I>I3) + (I>I2) + (I>I1) + (I>I0) );
    k = k0(first_row:last_row, first_column:last_column);

```

---

```
        % Compute and normalize the histogram
        h = sum(hist(k,0:q-1),2)' / numel(k);

        otherwise
            error('Invalid mapping')
    end

    if nargin>1;
        varargout(1) = {k};
    end

    if nargin>2;
        varargout(2) = {q};
    end

    if nargin>3;
        lims = [first_row, last_row, first_column, last_column];
        varargout(3) = {lims};
    end

function eta012 = eta(x,T)
eta012 = 2*(x>T) + (abs(x)<=T);

function vartheta012 = vartheta(x,y,T)
vartheta012 = 2*((abs(x)>=T) & (abs(y)>=T)) + ...
    (((abs(x)<T) & (abs(y)>=T)) | ((abs(x)>=T) & (abs(y)<T)));
```



# Publicaciones

## Revistas

- A. Fernández, M. X. Álvarez, and F. Bianconi. Texture description with binary gradient contours. *Optics and Lasers in Engineering*. (in press May 2011).
- M. J. Álvarez, E. González, F. Bianconi, J. Armesto, and A. Fernández. Colour and texture features for image retrieval in granite industry. *Dyna-Colombia*, 77(161):121–130, 2010.
- M. J. Álvarez, A. Fernández, E. González, F. Bianconi, F. J. Aguilar, and J. Armesto. Image segmentation using rotation-invariant multilayer coordinated clusters representation. *Anales de Ingeniería Gráfica*, 21:23–31, 2009.

## Actas de congresos

- S. A. Saetta, F. Bianconi, A. Fernández, M. J. Álvarez, D. López, M. Tini, and A. Tini. Caratterizzazione automatica dell’aspetto visivo di materiali e sue applicazioni nella filiera produttiva: metodi, problemi, prospettive. In *Atti del 1° Congresso del Coordinamento della Meccanica Italiana*, pages 106–107, 2010.
- M. J. Álvarez, E. González, F. Bianconi, J. Armesto, P. Arias, and A. Fernández. ¿Y ahora cómo encuentro una tabla de granito igual a la que se ha roto? In *Actas del Congreso Internacional de Minería Sostenible*, pages 889–900, Santiago de Compostela (Spain), April 2009.
- M. J. Álvarez, A. Fernández, E. González, F. Bianconi, F. J. Aguilar, and J. Armesto. Image segmentation using multilayer coordinated clusters representation. In *Proceedings of the International Joint Congress XXI INGEGRAF - XVII ADM*, page 137, 2009.



# Bibliografía

- [1] F. dell'Acqua and P. Gamba. Discriminating urban environments using multiscale texture and multiple sar images. *International Journal of Remote Sensing*, 27(18):3797–3812, 2006.
- [2] F. Agüera, M. A. Aguilar, and F. J. Aguilar. Detecting greenhouse changes from QuickBird imagery on the Mediterranean coast. *International Journal of Remote Sensing*, 27:4751–4767, 2006.
- [3] F. Agüera, F. J. Aguilar, and M. A. Aguilar. Using texture analysis to improve per-pixel classification of very high resolution images for mapping plastic greenhouses. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63:635–646, 2008.
- [4] T. Ahonen and M. Pietikäinen. Soft histograms for local binary patterns. In *Proceedings of the Finnish Signal Processing Symposium (FIN-SIG 2007)*, Oulu, Finland, 2007.
- [5] T. Ahonen and M. Pietikäinen. Image description using joint distribution of filter bank responses. *Pattern Recognition Letters*, 30(4):368–376, 2009.
- [6] A. Akono, E. Tonyé, A. N. Nyongui, and J.-P. Rudant. Nouvelle méthodologie d'évaluation des paramètres de texture d'ordre trois. *International Journal of Remote Sensing*, 24(9):1957–1967, 2003.
- [7] I. Aleksander and T. J. Stonham. Guide to pattern recognition using random-access memories. *IEE Journal on Computers and Digital Techniques*, 2(1):29–40, February 1979.
- [8] M. J. Álvarez, A. Fernández, E. González, F. Bianconi, F. J. Aguilar, and J. Armesto. Image segmentation using multilayer coordinated clusters representation. In *Proceedings of the International Joint Congress XXI INGEGRAF - XVII ADM*, page 137, 2009.
- [9] M. J. Álvarez, A. Fernández, E. González, F. Bianconi, F. J. Aguilar, and J. Armesto. Image segmentation using rotation-invariant multilayer coordinated clusters representation. *Anales de Ingeniería Gráfica*, 21:23–31, 2009.
- [10] M. J. Álvarez, E. González, F. Bianconi, J. Armesto, P. Arias, and A. Fernández. ¿Y ahora cómo encuentro una tabla de granito igual a la que se ha roto? In *Actas del Congreso Internacional de Minería Sostenible*, pages 889–900, Santiago de Compostela (Spain), April 2009.

- [11] M. J. Álvarez, E. González, F. Bianconi, J. Armesto, and A. Fernández. Colour and texture features for image retrieval in granite industry. *Dyna-Colombia*, 77(161):121–130, 2010.
- [12] M. Amadasun and R. King. Textural features corresponding to textural properties. *IEEE Transactions on Systems, Man and Cybernetics*, 19(5):1264–1274, 1989.
- [13] J. Austin. Grey scale N tuple processing. In Josef Kittler, editor, *Pattern Recognition: 4th International Conference*, volume 301 of *Lecture Notes in Computer Science*, pages 110–120, Cambridge, UK, March 1988. Springer-Verlag.
- [14] J. Austin. Image pre-processing with a generalised grey scale N tuple operator. Technical report, Department of Computer Science, University of New York, 1988.
- [15] D. H. Ballard and C. M. Brown. *Computer Vision*. Prentice Hall, 1982.
- [16] D. Barba and J. Ronsin. Image segmentation using new measure of the texture feature. In V. Cappellini and A. G. Constantinides, editors, *Digital Signal Processing-84*, pages 749–753, 1984.
- [17] A. Barcelo, E. Montseny, and P. Sobrevilla. On fuzzy texture spectrum for natural microtextures characterization. In *Proceedings EUSFLAT-LFA 2005*, pages 685–690, 2005.
- [18] A. Barcelo, P. Sobrevilla, and E. Montseny. Robustness and performance evaluation of the fuzzy texture spectrum encoding. In *Proceedings of the 2006 IEEE International Conference on Fuzzy Systems*, pages 1279–1286. IEEE, 2006.
- [19] A. Barcelo, E. Montseny, and P. Sobrevilla. Fuzzy texture unit and fuzzy texture spectrum for texture characterization. *Fuzzy Sets and Systems*, 158(3):239–252, 2007.
- [20] R. J. Baron. Mechanisms of human facial recognition. *International Journal of Man-Machine Studies*, 15(2):137–178, 1981.
- [21] A. Baykut, A. Atalay, A. Erçil, and M. Güler. Real-time defect inspection of textured surfaces. *Real-Time Imaging*, 6(1):17–27, 2000.
- [22] J. Beck, A. Sutter, and R. Ivry. Spatial frequency channels and perceptual grouping in texture segregation. *Computer Vision, Graphics, and Image Processing*, 37(2):299–325, 1987.
- [23] A. C. Beers, M. Agrawala, and N. Chaddha. Rendering from compressed textures. In *Proceedings of the ACM SIGGRAPH Conference on Computer Graphics*, pages 373–378, 1996.
- [24] J. R. Bergen and E. H. Adelson. Early vision and texture perception. *Nature*, 333(6171):363–364, 1988.

- [25] R. Bergman, H. Nachlieli, and G. Ruckenstein. Detection of textured areas in natural images using an indicator based on component counts. *Journal of Electronic Imaging*, 17(4):043003–1–13, 2008.
- [26] M. Bertalmio, L. Vese, G. Sapiro, and S. Osher. Simultaneous structure and texture image inpainting. *IEEE Transactions on Image Processing*, 12(8):882–889, 2003.
- [27] F. Bianconi and A. Fernández. Evaluation of the effects of Gabor filter parameters on texture classification. *Pattern Recognition*, 40(12):3325–3335, 2007.
- [28] F. Bianconi, A. Fernández, E. González, and F. Ribas. Texture classification through combination of sequential colour texture classifiers. In Luis Rueda, Domingo Mery, and Josef Kittler, editors, *Progress in Pattern Recognition, Image Analysis and Applications. Proceedings of the 12th Iberoamericann Congress on Pattern Recognition (CIARP 2007)*, volume 4756 of *Lecture Notes in Computer Science*, pages 231–240. Springer, 2008.
- [29] F. Bianconi, A. Fernández, E. González, D. Caride, and A. Calviño. Rotation-invariant colour texture classification through multilayer CCR. *Pattern Recognition Letters*, 30(8):765–773, 2009.
- [30] F. Bianconi and A. Fernández. On the occurrence probability of local binary patterns: a theoretical study. *Journal of Mathematical Imaging and Vision*, 40(3):259–268, 2011.
- [31] R. E. Blahut. *Principles and Practice of Information Theory*. Addison-Wesley, 1990.
- [32] T. Blaschke. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65:2–16, 2010.
- [33] W. W. Bledsoe and I. Browning. Pattern recognition and reading by machine. In *Proceedings of the Eastern Joint IRE-AIEE-ACM Computer Conference 1959*, pages 225–232. ACM, 1959.
- [34] J. S. de Bonet. Multiresolution sampling procedure for analysis and synthesis of texture images. In *SIGGRAPH '97: Proceedings of the 24th annual conference on Computer graphics and interactive techniques*, pages 361–368. ACM Press/Addison-Wesley Publishing Co., 1997.
- [35] C. Boukouvalas, J. Kittler, R. Marik, M. Mirmehdi, and M. Petrou. Ceramic tile inspection for colour and structural defects. In *Proceedings of Advanced Materials and Processing Technologies*, pages 390–399, 1995.
- [36] C. Boukouvalas, F. de Natale, G. de Toni, J. Kittler, R. Marik, M. Mirmehdi, M. Petrou, P. Le Roy, R. Salgari, and G. Vernazza. ASSIST: automatic system for surface inspection and sorting of tiles. *Journal of Materials Processing Technology*, 82:179–188, 1998.
- [37] J. N. Bradley, C. M. Brislawn, and T. Hopper. FBI wavelet/scalar quantization standard for gray-scale fingerprint image compression. In F. O. Huck and R. D. Juday, editors, *Proceedings of the Conference on Visual Information Processing II*, volume 1961, pages 293–304. SPIE, 1993.



- [38] J. N. Bradley and C. M. Brislawn. The wavelet/scalar quantization compression standard for digital fingerprint images. In *IEEE International Symposium on Circuits and Systems (ISCAS '94)*, volume 3, pages 205–208, 30 1994.
- [39] A. Bradley, P. Jackway, and B. Lovell. Classification in scale-space: applications to texture analysis. In *Proceedings of the International Conference on Information Processing in Medical Imaging*, pages 375–776, 1995.
- [40] U. Braga-Neto and E. Dougherty. Exact performance of error estimators for discrete classifiers. *Pattern Recognition*, 38:1799–1814, 2005.
- [41] P. Brodatz. *Textures: a photographic album for artists and designers*. Dover Publications, 1966.
- [42] J. M. H. du Buf, M. Kardan, and M. Spann. Texture feature performance for image segmentation. *Pattern Recognition*, 23(3-4):291–309, 1990.
- [43] T. Caelli and B. Julesz. On perceptual analyzers underlying visual texture discrimination: Part I. *Biological Cybernetics*, 28(3):167–175, 1978.
- [44] T. Caelli, B. Julesz, and E. Gilbert. On perceptual analyzers underlying visual texture discrimination: Part II. *Biological Cybernetics*, 29(4):201–214, 1978.
- [45] T. Caelli. Three processing characteristics of visual texture segmentation. *Spatial Vision*, 1(1):19–30, 1985.
- [46] J. M. Carstensen. Cooccurrence feature performance in texture classification. In *The 8th Scandinavian Conference on Image Analysis (SCIA 1993)*, pages 831–838, Tromsø, Norway, May 1993.
- [47] F. Chabat, G. Z. Yang, and D. M. Hansell. Obstructive lung diseases: Texture classification for differentiation at CT. *Radiology*, 228(3):871–877, 2003.
- [48] C.-I. Chang and Y. Chen. Gradient texture unit coding for texture analysis. *Optical Engineering*, 43(8):1891–1902, 2004.
- [49] C.-H. Chen and C.-Y. Lee. A JPEG-like texture compression with adaptive quantization for 3D graphics application. *Visual Computer*, 18(1):29–40, 2002.
- [50] Y. Chen and C.-I. Chang. A new application of texture unit coding to mass classification for mammograms. In *Proceedings of IEEE International Conference on Image Processing, 2004 (ICIP'04)*, volume 5, pages 3335–3338, 2004.
- [51] J. M. Coggins. *A Framework for Texture Analysis Based on Spatial Filtering*. PhD thesis, Computer Science Department, Michigan State University, 1982.
- [52] J. M. Coggins and A. K. Jain. A spatial filtering approach to texture analysis. *Pattern Recognition Letters*, 3(3):195–203, 1985.

- [53] R. W. Connors and C. A. Harlow. A theoretical comparison of texture algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-2(3):204–222, May 1980.
- [54] R. W. Connors and C. A. Harlow. Toward a structural textural analyzer based on statistical methods. *Computer Graphics and Image Processing*, 12(3):224–256, 1980.
- [55] R. W. Connors, C. W. McMillin, and K. Lin. Identifying and locating surface defects in wood: part of an automated lumber processing system. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-5(6):573–583, 1983.
- [56] G. R. Cross and A. K. Jain. Markov Random Field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 5(1):25–39, 1983.
- [57] CURET. Base de datos disponible en Internet en <http://www.cs.columbia.edu/CAVE/software/curet/>.
- [58] R. Datta, D. Joshi, J. Li, and J. Z. Wang. Image retrieval: Ideas, influences, and trends of the new age. *ACM Computing Surveys*, 40(2):5:1–5:60, 2008.
- [59] J. G. Daugman. Entropy reduction and decorrelation in visual coding by oriented neural receptive fields. *IEEE Transactions on Biomedical Engineering*, 36(1):107–114, 1989.
- [60] E. R. Davies. *Machine Vision, 3rd edition*. Morgan Kaufmann Publishers, 2005.
- [61] E. R. Davies. Introduction to texture analysis. In M. Mirmehdi, X. Xie, and J. Suri, editors, *Handbook of texture analysis*, pages 1–31. Imperial College Press, 2008.
- [62] L. S. Davis, S. A. Johns, and J. K. Aggarwal. Texture analysis using generalized co-occurrence matrices. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-1(3):251–259, 1979.
- [63] O. Demers. *Digital Texturing and Painting*. New Riders Publishing, 2001.
- [64] P. Diaconis and D. Freedman. On the statistics of vision: The Julesz conjecture. *Journal of Mathematical Psychology*, 24(2):112–138, 1981.
- [65] M.-P. Dubuisson-Jolly and A. Gupta. Color and texture fusion: Application to aerial image segmentation and GIS updating. *Image and Vision Computing*, 18(10):823–832, 2000.
- [66] R. O. Duda, P. E. Hart, and D. G. Stork. *Pattern Classification*. Wiley-Interscience, second edition, 2001.
- [67] A. Efros and T. Leung. Texture synthesis by non-parametric sampling. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 1033–1038, 1999.

- [68] A. Fernández, M. X. Álvarez, and F. Bianconi. Texture description with binary gradient contours. *Optics and Lasers in Engineering*. (in press May 2011).
- [69] A. Fernández, O. Ghita, E. González, F. Bianconi, and P. F. Whelan. Evaluation of robustness against rotation of LBP, CCR and ILBP features in granite texture classification. *Machine Vision and Applications*. (in press, published online 24 February 2010).
- [70] M. J. Ferreira, C. P. Santos, and J. Monteiro. Texture segmentation based on fuzzy grammar for cork parquet quality control. In *Proceedings of the IEEE International Symposium on Industrial Electronics (ISIE 2007)*, pages 1832–1837, Vigo, Spain, June 2007.
- [71] I. Fogel and D. Sagi. Gabor filters as texture discriminator. *Biological Cybernetics*, 61(2):103–113, 1989.
- [72] B. Fröba and A. Ernst. Face detection with the modified census transform. In *Proceedings of the Sixth IEEE International Conference on Automatic Face and Gesture Recognition (FGR 2004)*, pages 91–96, 2004.
- [73] A. Gagalowicz. Stochastic texture fields synthesis from a priori given second order statistics. In *Proceedings of the IEEE Computer Society Conference on Pattern Recognition and Image Processing*, pages 376–381, 1979.
- [74] M. M. Galloway. Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, 4(2):172–179, 1975.
- [75] L. Ganesan and P. Bhattacharyya. A new statistical approach for micro texture description. *Pattern Recognition Letters*, 16(5):471–478, 1995.
- [76] J. J. Gibson. *The Perception of the Visual World*. Houghton Mifflin, 1950.
- [77] P. Gong, D. J. Marceau, and P. J. Howarth. A comparison of spatial feature extraction algorithms for land-use classification with SPOT HRV data. *Remote Sensing of Environment*, 40:137–151, 1992.
- [78] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Pearson Prentice Hall, 2008.
- [79] L. van Gool, P. Dewaele, and A. Oosterlinck. Texture analysis anno 1983. *Computer Vision, Graphics, and Image Processing*, 29(3):336–357, 1985.
- [80] C. C. Gotlieb and H. E. Kreyszig. Texture descriptors based on co-occurrence matrices. *Computer Vision, Graphics, and Image Processing*, 51(1):70–86, 1990.
- [81] G. H. Granlund. The GOP parallel image processor. In L. Bolc and Z. Kulpa, editors, *Digital Image Processing Systems*, pages 200–227. Springer-Verlag, 1981.
- [82] M. Grau-Sánchez, E. Montseny, and P. Sobrevilla. On the use of fuzzy texture spectrum for homogeneous and textured image discrimination. In *Proceedings of the 2007 IEEE International Conference on Fuzzy Systems*, pages 1886–1891. IEEE, 2007.

- 
- [83] J. T. Guillén-Bonilla, E. V. Kurmyshev, and A. Fernández. Quantifying a similarity of classes of texture images. *Applied Optics*, 46:5562–5570, 2007.
- [84] Z. Guo, L. Zhang, and D. Zhang. A completed modeling of local binary pattern operator for texture classification. *IEEE Transactions on Image Processing*, 19(6):1657–1663, 2010.
- [85] Z. Guo, L. Zhang, and D. Zhang. Rotation invariant texture classification using LBP variance (LBPV) with global matching. *Pattern Recognition*, 43:706–719, 2010.
- [86] J. F. Haddon and J. F. Boyce. Co-occurrence matrices for image analysis. *Electronics and Communication Engineering Journal*, 5(2):71–83, April 1993.
- [87] D. J. Hand, H. Mannila, and P. Smyth. *Principles of data mining*. MIT Press, 2001.
- [88] R. M. Haralick, K. Shanmugam, and I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6):610–621, 1973.
- [89] R. M. Haralick. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):786–804, 1979.
- [90] R. J. Harrington. *Food and Wine Pairing: A Sensory Experience*. John Wiley & Sons, 2007.
- [91] D. Harwood, T. Ojala, M. Pietikäinen, S. Kelman, and L. S. Davis. Texture classification by center-symmetric auto-correlation, using Kullback discrimination of distributions. Technical Report CAR-TR-678, Center for Automation Research, University of Maryland, 1993.
- [92] J. K. Hawkins. Textural properties for pattern recognition. In B. C. Lipkin and A. Rosenfeld, editors, *Picture Processing and Psychopictorics*, pages 347–370. Academic Press, 1970.
- [93] K. C. Hayes, Jr, A. N. Shah, and A. Rosenfeld. Texture coarseness: further experiments. *IEEE Transactions on Systems, Man, and Cybernetics*, 4(5):467–472, 1974.
- [94] D.-C. He and L. Wang. Texture unit, texture spectrum, and texture analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4):509–512, 1990.
- [95] D.-C. He and L. Wang. Texture features based on texture spectrum. *Pattern Recognition*, 24(5):391–399, 1991.
- [96] D.-C. He and L. Wang. Unsupervised textural classification of images using the texture spectrum. *Pattern Recognition*, 25(3):247–255, 1992.
- [97] Y. Hel-Or, T. Malzbender, and D. Gelb. Synthesis and rendering of 3D textures. In *Texture 2003-3rd International Workshop on Texture Analysis and Synthesis*, pages 53–58, 2003.

- [98] L. Hepplewhite and T. J. Stonham. Surface inspection using texture recognition. In *Proceedings of the 12th International Conference on Pattern Recognition (ICPR'94)*, volume 1, pages 589–591, October 1994.
- [99] L. Hepplewhite and T. J. Stonham. Magnetic disk inspection using texture recognition. In *Proceedings of IEE Colloquium on Texture Classification: Theory and Applications*, pages 8/1–8/4, 1994.
- [100] L. Hepplewhite and T. J. Stonham. Texture classification using N-tuple pattern recognition. In *Proceedings of the 13th International Conference on Pattern Recognition (ICPR'96)*, volume 4, pages 159–163, August 1996.
- [101] L. Hepplewhite and T. J. Stonham. N-tuple texture recognition and the zero crossing sketch. *Electronics Letters*, 33(1):45–46, 1997.
- [102] L. Hepplewhite and T. J. Stonham. Image representation, texture and the fuzzy n-tuple. In *Proceedings of the 14th International Conference on Pattern Recognition, (ICPR'98)*, volume 2, pages 1028–1030. IEEE Computer Society, 1998.
- [103] R. M. Hodgson, D. G. Bailey, M. J. Naylor, A. L. M. Ng, and S. J. McNeill. Properties, implementations and applications of rank filters. *Image and Vision Computing*, 3(1):3–14, 1985.
- [104] X. Hu, C. V. Tao, and B. Prenzel. Automatic segmentation of high-resolution satellite imagery by integrating texture, intensity and color features. *Photogrammetric Engineering and Remote Sensing*, 71(12):1399–1406, 2005.
- [105] Y.-L. Huang, J.-H. Chen, and W.-C. Shen. Diagnosis of hepatic tumors with texture analysis in nonenhanced computed tomography images. *Academic Radiology*, 13(6):713–720, 2006.
- [106] D. K. Iakovidis, E. G. Keramidas, and D. Maroulis. Fuzzy local binary patterns for ultrasound texture characterization. In Aurélio Campilho and Mohamed Kamel, editors, *Proceedings of the 5th International Conference on Image Analysis and Recognition (ICIAR 2008)*, volume 5112 of *Lecture Notes in Computer Science*, pages 750–759, Póvoa de Varzim, Portugal, June 2008.
- [107] J. Iivarinen. Surface defect detection with histogram-based texture features. In *Intelligent Robots and Computer Vision XIX: Algorithms, Techniques, and Active Vision*, volume 4197 of *Proceedings of SPIE*, pages 140–145, 2000.
- [108] A. K. Jain, F. Farrokhnia, and D. H. Alman. Texture analysis of automotive finishes. In *Proceedings of SME Machine Vision Applications Conference*, pages 1–16, 1990.
- [109] A. K. Jain and F. Farrokhnia. Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, 24(12):1167–1186, 1991.
- [110] A. Jain and G. Healey. A multiscale representation including opponent color features for texture recognition. *IEEE Transactions on Image Processing*, 7(1):124–128, 1998.

- [111] A. K. Jain, S. Prabhakar, L. Hong, and S. Pankanti. Filterbank-based fingerprint matching. *IEEE Transactions on Image Processing*, 9(5):846–859, 2000.
- [112] K. Jalaja, C. Bhagvati, B. L. Deekshatulu, and A. K. Pujari. Texture element feature characterizations for CBIR. In *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2005*, volume 2, pages 733–736, 2005.
- [113] Jerry Wu. Base de datos disponible en Internet en <<http://www.macs.hw.ac.uk/texturelab/resources/databases/jwdb/>>.
- [114] H. Jin, Q. Liu, H. Lu, and X. Tong. Face detection using improved LBP under bayesian framework. In *Proceedings of the 3rd International Conference on Image and Graphics*, pages 306–309, 2004.
- [115] H. Jin, Q. Liu, X. Tang, and H. Lu. Learning local descriptors for face detection. In *Proceedings of IEEE International Conference on Multimedia and Expo*, pages 928–931. IEEE Computer Society, 2005.
- [116] B. Julesz. Visual pattern discrimination. *IRE Transactions on Information Theory*, IT-08:84–92, 1962.
- [117] B. Julesz and R. I. Hesse. Inability to perceive the direction of rotation movement of line segments. *Nature*, 225(5229):243–244, 1970.
- [118] B. Julesz, E. N. Gilbert, L. A. Shepp, and H. L. Frisch. Inability of humans to discriminate between visual textures that agree in second order statistics: revisited. *Perception*, 2(4):391–405, 1973.
- [119] B. Julesz. Experiments in the visual perception of texture. *Scientific American*, 232(4):34–43, 1975.
- [120] B. Julesz, E. N. Gilbert, and J. D. Victor. Visual discrimination of textures with identical third-order statistics. *Biological Cybernetics*, 31(3):137–140, 1978.
- [121] B. Julesz. Textons, the elements of texture perception, and their interactions. *Nature*, 290(5802):91–97, 1981.
- [122] B. Julesz and J. R. Bergen. Textons, the fundamental elements in preattentive vision and perception of textures. *The Bell System Technical Journal*, 62(6):1619–1645, 1983.
- [123] B. Julesz. Texton gradients: The texton theory revisited. *Biological Cybernetics*, 54(4-5):245–251, 1986.
- [124] S. Karkanis, K. Galousi, and D. Maroulis. Classification of endoscopic images based on texture spectrum. In *Proceedings of Workshop on Machine Learning in Medical Applications, Advanced Course in Artificial Intelligence (ACAI'99)*, pages 63–69, 1999.
- [125] J. M. Keller, S. Chen, and R. M. Crownover. Texture description and segmentation through fractal geometry. *Computer Vision, Graphics and Image Processing*, 45(2):150–166, 1989.

- [126] E. G. Keramidas, D. K. Iakovidis, D. Maroulis, and S. Karkanis. Efficient and effective ultrasound image analysis scheme for thyroid nodule detection. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 4633 LNCS:1052–1060, 2007.
- [127] E. N. Kirsanova and M. G. Sadovsky. Entropy approach in the analysis of anisotropy of digital images. *Open Systems and Information Dynamics*, 84:239–250, 2002.
- [128] K. Koffka. *Principles of Gestalt psychology*. Harcourt, Brace & World, 1935.
- [129] W. Köhler. *Gestalt psychology : an introduction to new concepts in modern psychology*. Liveright Publishing, 1947.
- [130] M. Köppen. Texture detection by genetic programming. In *Proceedings of the 2001 Congress on Evolutionary Computation*, pages 867–872, 2001.
- [131] V. Kovalev and M. Petrou. Multidimensional co-occurrence matrices for object recognition and matching. *Graphical Models and Image Processing*, 58(3):187–197, 1996.
- [132] KTH-TIPS y KTH-TIPS2. Bases de datos disponibles en Internet en <http://www.nada.kth.se/cvap/databases/kth-tips/>.
- [133] P. Kube and A. Pentland. On the imaging of fractal surfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(5):704–707, 1988.
- [134] C. Küblbeck and A. Ernst. Face detection and tracking in videos sequences using the modified census transform. *Image and Vision Computing*, 24:564–572, 2006.
- [135] J. J. Kulikowski, S. Marčelja, and P. O. Bishop. Theory of spatial position and spatial frequency relations in the receptive fields of simple cells in the visual cortex. *Biological Cybernetics*, 43(3):187–198, 1982.
- [136] S. Y. Kung and J. S. Taur. Decision-based neural networks with signal/image classification applications. *IEEE Transactions on Neural Networks*, 6(1):170–181, 1995.
- [137] I. Kunttu, L. Lepistö, J. Rauhamaa, and A. Visa. Image retrieval without segmentation. In *Proceedings of the 10th Finnish Artificial Intelligence Conference*, pages 164–169, 2002.
- [138] I. Kunttu, L. Lepistö, J. Rauhamaa, and A. Visa. Binary co-occurrence matrix in image database indexing. In *Proceedings of the 13th Scandinavian Conference on Image Analysis (SCIA 2003)*, volume 2749 of *Lecture Notes in Computer Science*, pages 1090–1097, Halmstad, Sweden, 2003. Springer.
- [139] E. V. Kurmyshev and M. Cervantes. A quasi-statistical approach to digital binary image representation. *Revista Mexicana de Física*, 42(1):104–116, 1996.

- [140] E. V. Kurmyshev and R. Soto. Digital pattern recognition in the coordinated cluster representation. In *Proceedings of 2nd Nordic Signal Processing Symposium (NORSIG 1996)*, pages 463–466, Espoo, Finland, September 1996.
- [141] E. Kurmyshev, F. Cuevas, and R. Sánchez. Noisy binary texture recognition using the coordinated cluster transform. *Computación y Sistemas*, 6(3):196–203, 2003.
- [142] E. V. Kurmyshev, R. E. Sánchez-Yáñez, and A. Fernández. Colour texture classification for quality control of polished granite tiles. In *Proceedings of the Third IASTED International Conference on Visualization, Imaging and Image Processing (VIIP 2003)*, volume II, pages 603–608. ACTA Press, August 2003.
- [143] E. V. Kurmyshev and R. E. Sánchez-Yáñez. Comparative experiment with colour texture classifiers using the CCR feature space. *Pattern Recognition Letters*, 26(9):1346–1353, 2005.
- [144] O. Lahdenoja, M. Laiho, and A. Paasio. Reducing the feature vector length in local binary pattern based face recognition. In *Proceedings of the IEEE International Conference on Image Processing, 2005 (ICIP'05)*, volume 2, pages 914–917, Genoa, Italy, September 11-14 2005.
- [145] K. I. Laws. Rapid texture identification. In *Conference on Image Processing for Missile Guidance*, volume 238 of *Proceedings of SPIE*, pages 376–380, San Diego, CA, 1980.
- [146] Svetlana Lazebnik, Cordelia Schmid, and Jean Ponce. A sparse texture representation using local affine regions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(8):1265–1278, 2005.
- [147] LBP Bibliography. Bibliografía sobre la LBP disponible en Internet en [http://www.ee.oulu.fi/mvg/page/lbp\\_bibliography/](http://www.ee.oulu.fi/mvg/page/lbp_bibliography/).
- [148] D.-C. Lee and T. Schenk. Image segmentation from texture measurement. In *International Archives of photogrammetry and Remote Sensing, Comm. III*, pages 195–199, 1992.
- [149] G. G. Lendaris and G. L. Stanley. Diffraction-pattern sampling for automatic pattern recognition. *Proceedings of the IEEE*, 58(2):198–216, 1970.
- [150] L. Lepistö, I. Kunttu, J. Autio, and A. Visa. Comparison of some content-based image retrieval systems with rock texture images. In *Proceedings of the 10th Finnish Artificial Intelligence Conference*, pages 156–163, 2002.
- [151] L. Lepistö, I. Kunttu, J. Autio, and A. Visa. Classification of non-homogenous texture images by combining classifiers. In *IEEE International Conference on Image Processing*, volume 1, pages 981–984, 2003.
- [152] S. Liao, M. W. K. Law, and A. C. S. Chung. Dominant local binary patterns for texture classification. *IEEE Transactions on Image Processing*, 18(5):1107–1118, 2009.



- [153] C. S. Lindsey and M. Strömberg. Image classification using the frequencies of simple features. *Pattern Recognition Letters*, 21:265–268, 2000.
- [154] Y. Liu, D. Zhang, G. Lu, and W.-Y. Ma. A survey of content-based image retrieval with high-level semantics. *Pattern Recognition*, 40(1):262–282, 2007.
- [155] G. E. Lowitz. Can a local histogram really map texture information? *Pattern Recognition*, 16(2):141–147, 1983.
- [156] L. Ma, T. Tan, Y. Wang, and D. Zhang. Personal identification based on iris texture analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(12):1519–1533, 2003.
- [157] F. J. Madrid-Cuevas, R. Medina, M. Prieto, N. L. Fernández, and A. Carmona. Simplified texture unit: A new descriptor of the local texture in gray-level images. In Francisco J. Perales López, Aurélio C. Campilho, Nicolas Pérez de la Blanca, and Alberto Sanfeliu, editors, *Pattern Recognition and Image Analysis, Proceedings of the First Iberian Conference (IbPRIA 2003)*, volume 2652 of *Lecture Notes in Computer Science*, pages 470–477. Springer, 2003.
- [158] T. Mäenpää, M. Pietikäinen, and T. Ojala. Texture classification by multi-predicate local binary pattern operators. In *Proceedings of the 15th International Conference on Pattern Recognition (ICPR'00)*, volume 3, pages 939–942, Barcelona, Spain, 2000.
- [159] T. Mäenpää, T. Ojala, and M. Soriano. Robust texture classification by subsets of local binary patterns. In *Proceedings of the 15th International Conference on Pattern Recognition (ICPR'00)*, volume 3, pages 935–938, Barcelona, Spain, 2000.
- [160] T. Mäenpää and M. Pietikäinen. Classification with color and texture: jointly or separately? *Pattern Recognition*, 37(8):1629–1640, 2004.
- [161] T. Mäenpää and M. Pietikäinen. Texture analysis with local binary patterns. In C. H. Chen and P. S. P. Wang, editors, *Handbook of Pattern Recognition and Computer Vision (3rd Edition)*, pages 197–216. World Scientific Publishing, 2005.
- [162] O. Maldonado, D. Vicente, and M. Graña. CBIR indexing hyperspectral images. In *International Geoscience and Remote Sensing Symposium (IGARSS)*, volume 2, pages 1202–1205, 2005.
- [163] J. O. Maldonado. *Estudio de métodos de indexación y recuperación en bases de datos de imágenes*. PhD thesis, Universidad del País Vasco/Euskal Herriko Unibertsitatea, 2008.
- [164] J. Malik and P. Perona. Preattentive texture discrimination with early vision mechanisms. *Journal of the Optical Society of America. A, Optics and image science*, 7(5):923–932, 1990.
- [165] J. Mao and A. K. Jain. Texture classification and segmentation using multiresolution simultaneous autoregressive models. *Pattern Recognition*, 25(2):173–188, 1992.

- [166] S. Marčelja. Mathematical description of the responses of simple cortical cells. *Journal of the Optical Society of America*, 70(11):1297–1300, 1980.
- [167] D. Marr. Early processing of visual information. *Philosophical transactions of the Royal Society of London. Series B: Biological sciences*, 275(942):483–519, 1976.
- [168] O. R. Mitchell, C. R. Myers, and W. Boyne. A max-min measure for image texture analysis. *IEEE Transactions on Computers*, C-26(4):408–414, April 1977.
- [169] A. Mojsilović, J. Kovačević, J. Hu, R. J. Safranek, and K. Ganapathy. Matching and retrieval based on the vocabulary and grammar of color patterns. *IEEE Transactions on Image Processing*, 9(1):38–54, 2000.
- [170] D. C. Montgomery and G. C. Runger. *Applied Statistics and Probability for Engineers*. John Wiley & Sons, second edition, 1999.
- [171] N. R. Mudigonda, R. Rangayyan, and J. E. L. Desautels. Gradient and texture analysis for the classification of mammographic masses. *IEEE Transactions on Medical Imaging*, 19(10):1032–1043, 2000.
- [172] V. S. Nalwa. *A Guided Tour of Computer Vision*. Addison-Wesley, 1993.
- [173] P. P. Ohanian and R. C. Dubes. Performance evaluation for four classes of textural features. *Pattern Recognition*, 25(8):819–833, 1992.
- [174] E. Oja and K. Valkealahti. Co-occurrence map: Quantizing multidimensional texture histograms. *Pattern Recognition Letters*, 17(7):723–730, 1996.
- [175] T. Ojala, M. Pietikäinen, and D. Harwood. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions. In *Proceedings of the 12th IAPR International Conference on Computer Vision Image Processing*, volume 1, pages 582–585, 1994.
- [176] T. Ojala, M. Pietikäinen, and D. Harwood. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29(1):51–59, 1996.
- [177] T. Ojala and M. Pietikäinen. Unsupervised texture segmentation using feature distributions. *Pattern Recognition*, 32:477–486, 1999.
- [178] T. Ojala, M. Pietikäinen, and J. Kyllönen. Gray level cooccurrence histograms via learning vector quantization. In *Proceedings of the 11th Scandinavian Conference on Image Analysis (SCIA 1999)*, pages 103–108, Kangerlussuaq, Greenland, 1999.
- [179] T. Ojala, K. Valkealahti, E. Oja, and M. Pietikäinen. Texture discrimination with multidimensional distributions of signed gray level differences. *Pattern Recognition*, 34:727–739, 2001.
- [180] T. Ojala, M. Pietikäinen, and T. Mäenpää. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7):971–987, 2002.

- [181] T. Ojala, M. Pietikäinen, T. Mäenpää, J. Viertola, J. Kyllönen, and S. Huovinen. Outex - new framework for empirical evaluation of texture analysis algorithms. In *Proceedings of the 16th International Conference on Pattern Recognition (ICPR'02)*, volume 1, pages 701–706, Quebec, Canada, 2002. IEEE Computer Society.
- [182] A Oliver. *Automatic mass segmentation in mammographic images*. PhD thesis, Universitat de Girona, 2007.
- [183] OuTeX. Base de datos disponible en Internet en <http://www.outex.oulu.fi/>.
- [184] P. Paclík, S. Verzakov, and R. P. W. Duin. Improving the maximum-likelihood co-occurrence classifier: A study on classification of inhomogeneous rock images. In *Proceedings of the 14th Scandinavian Conference on Image Analysis (SCIA 2005)*, volume 3540 of *Lecture Notes in Computer Science*, pages 998–1008. Springer, 2005.
- [185] D. K. Panjwani and G. Healey. Markov random field models for unsupervised segmentation of textured color images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(18):939–954, 1995.
- [186] M. Partio, B. Cramariuc, M. Gabbouj, and A. Visa. Rock texture retrieval using gray level co-occurrence matrix. In *Proceedings of the 5th Nordic Signal Processing Symposium, 2002 (NORSIG 2002)*, on board Hurtigruten, Norway, October 2002.
- [187] D. Patel and T. J. Stonham. A single layer neural network for texture discrimination. In *IEEE International Symposium on Circuits and Systems, 1991*, volume 5, pages 2656–2660, June 1991.
- [188] D. Patel and T. J. Stonham. Texture image classification and segmentation using rank-order clustering. In *Proceedings of the 11th International Conference on Pattern Recognition (ICPR'92)*, volume 3, pages 92–95. IEEE Computer Society, 2002.
- [189] D. Patel and T. J. Stonham. Unsupervised/supervised texture segmentation and its application to real-world data. In Petros Maragos, editor, *Visual Communications and Image Processing '92*, volume 1818 of *Proceedings of SPIE*, pages 1206–1217, Boston, MA, USA, November 1992. SPIE.
- [190] D. Patel and T. J. Stonham. Segmentation of potash mine images using multi-layer perceptron networks. In *Proceedings of the Second International Conference on Automation, Robotics and Computer Vision (ICARCV'92)*, Singapore, September 1992.
- [191] A. P. Pentland. On describing complex surface shapes. *Image and Vision Computing*, 3(4):153–162, 1985.
- [192] M. Petrou and P. García Sevilla. *Image Processing. Dealing with Texture*. Wiley Interscience, 2006.

- [193] C. P. Pfleeger and S. L. Pfleeger. *Security in Computing, 4th Edition*. Prentice Hall PTR, 2006.
- [194] R. W. Picard, T. Kabir, and F. Liu. Real-time recognition with the entire Brodatz texture database. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 638–639, 1993.
- [195] M. Pietikäinen, T. Ojala, J. Nisula, and J. Heikkinen. Experiments with two industrial problems using texture classification based on feature distributions. In *Proceedings of SPIE*, volume 2354, pages 197–204, 1994.
- [196] A. B. Poirson and B. A. Wandell. Pattern-color separable pathways predict sensitivity to simple colored patterns. *Vision Research*, 36(4):515–526, 1996.
- [197] S. Poongunzali and G. Ravindran. Evaluation of feature extraction methods for classification of liver abnormalities in ultrasound images. *International Journal of Biomedical Engineering and Technology*, 1(2):134–143, 2007.
- [198] J. M. Prats-Montalbán and A. Ferrer. Integration of colour and textural information in multivariate image analysis: Defect detection and classification issues. *Journal of Chemometrics*, 21(1-2):10–23, 2007.
- [199] W. K. Pratt. *Digital Image Processing*. Wiley-Interscience, 4th edition, 2007.
- [200] Real Academia Española. *Diccionario de la Lengua Española*. Espasa Calpe, 22nd edition, 2001.
- [201] T. Randen and J. H. Husøy. Filtering for texture classification: A comparative study. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(4):291–310, 1999.
- [202] J. A. Recio-Recio. *Técnicas de extracción de características y clasificación de imágenes orientada a objetos aplicadas a la actualización de bases de datos de ocupación del suelo*. PhD thesis, Universidad Politécnica de Valencia, 2009.
- [203] A. Rosenfeld and E. B. Troy. Visual texture analysis. Technical Report TR-116, Computer Science Center, University of Maryland, College Park, 1970.
- [204] A. Rosenfeld and B. S. Lipkin. Texture synthesis. In A. Rosenfeld and B. S. Lipkin, editors, *Picture Processing and Psychopictorics*, pages 309–322. Academic Press, 1970.
- [205] A. Rosenfeld. Visual texture analysis: An overview. Technical Report TR-406, Computer Science Center, University of Maryland, College Park, 1975.
- [206] A. Rosenfeld, C. Wang, and A. Y. Wu. Multispectral texture. *IEEE Transactions on Systems Man and Cybernetics*, 12(1):79–84, 1982.

- [207] Y. Rubner, J. Puzicha, C. Tomasi, and J. M. Buhmann. Empirical evaluation of dissimilarity measures for color and texture. *Computer Vision and Image Understanding*, 84:25–43, 2001.
- [208] S. Sadie and G. Grove. *The New Grove Dictionary of Music and Musicians*. MacMillan, 1980.
- [209] S. A. Saetta, F. Bianconi, A. Fernández, M. J. Álvarez, D. López, M. Tini, and A. Tini. Caratterizzazione automatica dell’aspetto visivo di materiali e sue applicazioni nella filiera produttiva: metodi, problemi, prospettive. In *Atti del 1° Congresso del Coordinamento della Meccanica Italiana*, pages 106–107, 2010.
- [210] R. E. Sánchez-Yáñez, E. V. Kurmyshev, and F. J. Cuevas. A framework for texture classification using the coordinated clusters representation. *Pattern Recognition Letters*, 24(1-3):21–31, 2003.
- [211] R. E. Sánchez-Yáñez, E. V. Kurmyshev, and A. Fernández. One-class texture classifier in the CCR feature space. *Pattern Recognition Letters*, 24(9-10):1503–1511, 2003.
- [212] O. Sertel, J. Kong, G. Lozanski, A. Shana’ah, U. Catalyurek, J. Saltz, and M. Gurcan. Texture classification using nonlinear color quantization: application to histopathological image analysis. In *Proceedings of the 2008 IEEE International Conference on Acoustics, Speech and Image Processing (ICASSP 2008)*, pages 597–600, March-April 2008.
- [213] L. G. Shapiro and G. C. Stockman. *Computer Vision*. Prentice Hall, 2001.
- [214] M. Sharma and S. Singh. Evaluation of texture methods for image analysis. In *Proceedings of the Seventh Australian and New Zealand Intelligent Information Systems Conference (ANZIIS 2001)*, pages 117–121, November 2001.
- [215] H. C. Shen and C. Y. C. Bie. Feature frequency matrices as texture image representation. *Pattern Recognition Letters*, 13:195–205, 1992.
- [216] L. H. Siew, R. M. Hodgson, and E. J. Wood. Texture measures for carpet wear assessment. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(1):92–105, January 1988.
- [217] S. Singh and M. Sharma. Texture analysis experiments with Meastex and Vistex benchmarks. In *Proceeding of the Second International Conference on Advances in Pattern Recognition (ICAPR 2001)*, volume 2013 of *Lecture Notes in Computer Science*, pages 417–424, Rio de Janeiro, Brazil, March 2001. Springer-Verlag.
- [218] M. Singh and S. Singh. Spatial texture analysis: a comparative study. In *Proceedings of the 16th International Conference on Pattern Recognition (ICPR’02)*, volume 1, pages 676–679. IEEE Computer Society, 2002.
- [219] F. Smeraldi. Ranklets: orientation selective non-parametric features applied to face detection. In *Proceedings of the 16th International Conference on Pattern Recognition (ICPR’02)*, volume 3, pages 379–382. IEEE Computer Society, 2002.

- [220] F. Smeraldi. A nonparametric approach to face detection using ranklets. In G. Goos, J. Hartmanis, and J. van Leeuwen, editors, *Proceedings of the 4th International Conference on Audio- and Video-Based Biometric Person Authentication (AVBPA 2003)*, volume 2688 of *Lecture Notes in Computer Science*, pages 351–359, Guildford, UK, June 2003.
- [221] A. W. M. Smeulders, M. Worring, S. Santini, A. Gupta, and R. Jain. Content-based image retrieval at the end of the early years. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(12):1349–1380, 2000.
- [222] G. Smith and I. Burns. Measuring texture classification algorithms. *Pattern Recognition Letters*, 18(14):1495–1501, 1997.
- [223] K. Y. Song, J. Kittler, and M. Petrou. Defect detection in random colour texture. *Image Vision and Computing*, 14(9):667–683, 1996.
- [224] M. Sonka, V. Hlavac, and R. Boyle. *Image Processing, Analysis and Machine Vision, Third Edition*. Thomson, 2005.
- [225] P. Southam and R. Harvey. Towards texture classification in real scenes. In *Proceedings of the British Machine Vision Conference*, pages 240–250, Oxford, UK, September 2005.
- [226] K. A. Stevens. Representing and analyzing surface orientation. In P. H. Winston and R. H. Brown, editors, *Artificial intelligence: An MIT perspective*, pages 104–125. MIT Press, 1979.
- [227] E. W. Steyerberg, F. E. Harrell, G. J. J. M. Borsboom, M. J. C. Eijkemans, Y. Vergouwe, and J. D. F. Habbema. Internal validation of predictive models: Efficiency of some procedures for logistic regression analysis. *Journal of Clinical Epidemiology*, 54(8):774–781, 2001.
- [228] R. Suguna and P. Anandhakumar. A rotation invariant pattern operator for texture characterization. *International Journal of Computer Science and Network Security*, 10(4):120–129, 2010.
- [229] C. Sun and W. G. Wee. Neighboring gray level dependence matrix for texture classification. *Computer Vision, Graphics, and Image Processing*, 23(3):341–352, 1983.
- [230] A. Sutter, J. Beck, and N. Graham. Contrast and spatial variables in texture segregation: testing a simple spatial-frequency channels model. *Perception and Psychophysics*, 46(4):312–332, 1989.
- [231] H. Tamura, T. Mori, and T. Yamawaki. Textural features corresponding to visual perception. *IEEE Transactions on Systems, Man, and Cybernetics*, 8:460–473, June 1978.
- [232] T. S. C. Tan and J. Kittler. Colour texture analysis using colour histogram. *IEE Proceedings - Vision, Image and Signal Processing*, 141(6):403–412, December 1994.

- [233] X. Tan and B. Triggs. Enhanced local texture feature sets for face recognition under difficult lighting conditions. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 4778 LNCS:168–182, 2007.
- [234] X. Tan and B. Triggs. Enhanced local texture feature sets for face recognition under difficult lighting conditions. *IEEE Transactions on Image Processing*, 19(6):1635–1650, 2010.
- [235] J. S. Taur and C.-W. Tao. Texture classification using a fuzzy texture spectrum and neural networks. *Journal of Electronic Imaging*, 7(1):29–35, 1998.
- [236] K. W. Tobin, T. P. Karnowski, and R. K. Ferrell. Image retrieval in the industrial environment. In *Proceedings of SPIE - The International Society for Optical Engineering*, volume 3652, pages 184–192, 1999.
- [237] F. Tomita and S. Tsuji. *Computer Analysis of Visual Textures*. Kluwer Academic Publishers, 1990.
- [238] M. Tuceryan and A. K. Jain. Texture analysis. In C. H. Chen, L. F. Pau, and P. S. P. Wang, editors, *Handbook of Pattern Recognition and Computer Vision (2nd Edition)*, pages 207–248. World Scientific Publishing, 1998.
- [239] M. Turk and A. Pentland. Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 3(1):71–86, 1991.
- [240] M. R. Turner. Texture discrimination by Gabor functions. *Biological Cybernetics*, 55(2-3):71–82, 1986.
- [241] O. Tuzel, L. Yang, P. Meer, and D. J. Foran. Classification of hematologic malignancies using texton signatures. *Pattern Analysis and Applications*, 10(4):277–290, 2007.
- [242] M. Unser. Sum and difference histograms for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(1):118–125, January 1986.
- [243] M. Unser. Local linear transforms for texture measurements. *Signal Processing*, 11(1):61–79, July 1986.
- [244] USC-SIPI. Base de datos disponible en Internet en <http://sipi.usc.edu/database/>.
- [245] K. Valkealahti and E. Oja. Reduced multidimensional co-occurrence histograms in texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(1):90–94, 1998.
- [246] M. Varma and A. Zisserman. Texture classification: Are filter banks necessary? In *Proceedings of the 2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'03)*, volume 2, pages 691–698, June 2003.

- [247] M. Varma and A. Zisserman. A statistical approach to material classification using image patch exemplars. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(11):2032–2047, 2009.
- [248] A. L. Vickers and J. W. Modestino. A maximum likelihood approach to texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-4(1):61–68, January 1982.
- [249] K. Vijayarekha and R. Govindaraj. Citrus fruit external defect classification using wavelet packet transform features and ANN. In *Proceedings of the IEEE International Conference on Industrial Technology*, pages 2872–2877, 2006.
- [250] D. G. Vince, K. J. Dixon, R. M. Cothren, and J. F. Cornhill. Comparison of texture analysis methods for the characterization of coronary plaques in intravascular ultrasound images. *Computerized Medical Imaging and Graphics*, 24:221–229, 2000.
- [251] VisTex. Base de datos disponible en Internet en <http://vismod.media.mit.edu/vismod/imagery/VisionTexture/>.
- [252] L. Wang and D.-C. He. Texture classification using texture spectrum. *Pattern Recognition*, 23(8):905–910, 1990.
- [253] L. Wang and D.-C. He. A new statistical approach for texture analysis. *Photogrammetric Engineering and Remote Sensing*, 56(1):61–66, 1990.
- [254] E. W. Weisstein. *CRC Concise Encyclopedia of Mathematics*. Chapman & Hall/CRC, second edition, 2002.
- [255] J. S. Weszka, C. R. Dyer, and A. Rosenfeld. A comparative study of texture measures for terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, 6(4):269–286, April 1976.
- [256] C.-M. Wu and Y.-C. Chen. Statistical feature matrix for texture analysis. *CVGIP: Graphical Models and Image Processing*, 54(5):407–419, 1992.
- [257] X. Xie and M. Mirmehdi. A galaxy of texture features. In M. Mirmehdi, X. Xie, and J. Suri, editors, *Handbook of texture analysis*, pages 375–406. Imperial College Press, 2008.
- [258] B. Xu and P. Gong. A comparison of reduced texture spectrum approach with gray level reduction schemes for land-use classification with sampled Ikonos imagery. In *Proceedings ICII 2001, Beijing, 2001*, volume 1, pages 139–145, 2001.
- [259] B. Xu, P. Gong, E. Seto, and R. Spear. Comparison of gray-level reduction and different texture spectrum encoding methods for land-use classification using a panchromatic Ikonos image. *Photogrammetric Engineering and Remote Sensing*, 69(5):529–536, 2003.
- [260] C. Yao and S. Chen. Retrieval of translated, rotated and scaled color textures. *Pattern Recognition*, 36(4):913–929, 2003.



- 
- [261] R. Zabih and J. Woodfill. Non-parametric local transforms for computing visual correspondence. In *Proceedings of the 3rd European Conference on Computer Vision (ECCV)*, pages 151–158, Stockholm, Sweden, May 1994. Springer-Verlag.
- [262] K. Zagoris, S. A. Chatzichristofis, N. Papamarkos, and Y. S. Boutalis. img(Anaktisi): A web content based image retrieval system. In *SISAP '09: Proceedings of the Second International Workshop on Similarity Search and Applications*, pages 154–155. IEEE Computer Society, 2009.
- [263] Y. Zhang. Texture-integrated classification of urban treed areas in high-resolution color-infrared imagery. *Photogrammetric Engineering and Remote Sensing*, 67(12):1359–1365, 2001.
- [264] H. Zhou, R. Wang, and C. Wang. A novel extended local-binary-pattern operator for texture analysis. *Information Sciences*, 178(22):4314–4325, 2008.
- [265] S. W. Zucker, A. Rosenfeld, and L. S. Davis. Picture segmentation by texture discrimination. *IEEE Transactions on Computers*, C-24(12):1228–1233, 1975.
- [266] S. W. Zucker and K. Kant. Multiple-level representation for texture discrimination. In *Proceedings of the IEEE Computer Society Conference on Pattern Recognition and Image Processing*, pages 609–614, 1981.

# Acrónimos

- AFIS** *Automatic Fingerprint Identification Systems*. 12
- BCM** *Binary Co-Occurrence Matrix*. 36
- BGC** *Binary Gradient Contours*. 17, 41, 43–49, 65, 70, 71
- BTCS** *Binary Texture Co-occurrence Spectrum*. 31–33, 35
- CAT** *Computerized Axial Tomography*. 13
- CBIR** *Content Based Image Retrieval*. 9, 12, 71
- CCR** *Coordinated Clusters Representation*. 31, 32, 36
- CLBP** *Completed Local Binary Patterns*. 32, 65
- CUReT** *Columbia-Utrecht Reflectance and Texture Database*. 53, 54
- DH** *Difference Histogram*. 26
- DLBP** *Dominant Local Binary Patterns*. 37
- ECM** *Edge Co-occurrence Matrix*. 35
- EF** *Edge Frequency*. 16
- ELBP** *Extended Local Binary Patterns*. 37
- FFM** *Feature Frequency Matrices*. 35
- FLBP** *Fuzzy Local Binary Patterns*. 39
- FSTS** *Fuzzy Simplified Texture Spectrum*. 39
- FTS** *Fuzzy Texture Spectrum*. 39
- FZCTCS** *Fuzzy Zero Crossing Texture Co-occurrence Spectrum*. 39
- GCM** *Generalized Co-Occurrence Matrices*. 35
- GIF** *Graphics Interchange Format*. 11
- GLCM** *Grey-Level Co-occurrence Matrices*. 24, 26, 38

- GLD** *Gray-Level Difference*. 15, 26, 65
- GLRL** *Gray Level Run Length*. 15
- GLTCS** *Grey-Level Texture Co-occurrence Spectrum*. 33, 34
- GOP** *General Operator Processor*. 15
- GTUC** *Gradient Texture Unit Coding*. 30, 65
- HRIMAC** *Herramienta de Recuperación de Imágenes Mamográficas por Análisis de Contenido para el Asesoramiento en el Diagnóstico del Cáncer de Mama*. 12
- ILBP** *Improved Local Binary Patterns*. 32, 71
- JPEG** *Joint Photographic Experts Group*. 11
- KTH-TIPS** *Textures under varying Illumination, Pose and Scale*. 53, 54
- LBP** *Local Binary Patterns*. 30–32, 35–39, 44–49, 70, 71
- LBP/C** *Joint LBP and contrast measure*. 35
- LBP/VAR** *Joint LBP and variance measure*. 35
- LBPV** *LBP Variance*. 36
- LED** *Light-Emitting Diode*. 57
- LEP** *Local Edge Pattern*. 36
- LTP** *Local Ternary Patterns*. 29, 30, 65
- LVQ** *Linear Vector Quantization*. 38
- MCT** *Modified Census Transform*. 32
- MDCM** *Multidimensional Co-occurrence Matrices*. 35
- MIT** *Massachusetts Institute of Technology*. 56
- MRF** *Markov Random Fields*. 14, 16
- MRI** *Magnetic Resonance Images*. 13
- MVG** *Machine Vision Group*. 54
- NGLDS** *Neighboring Gray Level Dependence Statistics*. 15
- NGLE** *Number of Gray Level Extrema*. 15
- NGTDM** *Neighborhood Gray Tone Difference Matrices*. 16
- OBIA** *Object Based Image Analysis*. 66

- 
- PNG** *Portable Network Graphics*. 11
- PSM** *Power Spectral Method*. 15
- RFTS** *Reduced Fuzzy Texture Spectrum*. 39
- RTU** *Reduced Texture Units*. 29, 39
- SAVHC** *Surrounding, Alternating, Vertical and Horizontal Constrast*. 38
- SDH** *Sum and Difference Histograms*. 27
- SGLDM** *Spatial Gray-Level Dependence Method*. 15
- SH** *Sum Histogram*. 26
- SOM** *Self Organizing Maps*. 38
- STS** *Simplified Texture Spectrum*. 29
- STU** *Simplified Texture Units*. 29, 65
- TCS** *Texture Co-occurrence Spectrum*. 49
- TIFF** *Tagged Image File Format*. 52
- TS** *Texture Spectrum*. 16, 27, 29, 31, 35, 36, 38, 39
- TU** *Texture Units*. 27, 29–31, 35, 65
- UIUCTex** *University of Illinois at Urbana–Champaign Texture*. 55
- USC-SIPI** *Signal & Image Processing Institute*. 52
- VisTex** *Vision Texture*. 56
- VQ** *Vector Quantization*. 11
- WSQ** *Wavelet/Scalar Quantization*. 13
- ZCTCS** *Zero Crossing Texture Co-occurrence Spectrum*. 35, 39



# Índice alfabético

- álbum de Brodatz, 5, 52, 56
- albedo, 55
- análisis
  - de imágenes basado en objetos, 66
  - de imágenes digitales, 7, 8, 19
  - de terrenos, 11
  - de texturas, 1–4, **7**, 8, 9, 11–13, 15, 17, 33, 51–54, 69
- búsqueda y recuperación automáticas, **9**, 12, 71
- baldosa de granito, 52, 56, 57, 61
- banco
  - de filtros, 7
  - de pruebas, 18, 54, 55, 66
- bordes, 7, 9, 35, 37
  - detección, 33, 36, 66
- brillo, 1, 3
- campo aleatorio de Markov, *véase* MRF
- características de textura, 5, 6, 10, 14, 26, 47
  - de Haralick, 15, 16
  - dimensión, 26, 44, 48, 49, 66
  - espacio, 13, 29, 36, 59
  - extracción, 4, 13, 26, **36**
  - galaxia, 13
  - vector, 8, **13**, 22, 58
- clasificación, **8**, 12, 17, 38, 51–57, 59, 61, 63, 66, 70, 71
  - no supervisada, 8
  - supervisada, 8, 61, 70
- clustering, *véase* conglomeración
- coeficiente de Jaccard, 36
- color, 1–4, 9
- compresión, **11**, 13
- conglomeración, 38
- conjetura de Julez, 6, 7
- conjunto
  - de aprendizaje, *véase* entrenamiento
  - de validación, 52, 55, 58–60
- contraste, 1, 5, 35, 36
- control de calidad, 8, 13
- cuantización
  - de niveles, 21, 22, 27, 45, 48, 57
  - multidimensional, *véase* LVQ
- delta de Dirac, 24
- descomposición jerárquica, 3, 15
- descriptores de textura, **13**, 14–21, 26, 34–37, 39, 48, 51, 69–71
  - estadísticos, 14, 15, 19
  - estructurales, 6, 14, 15
  - familia, 17, 21, **41**, 42, 46, 47, 70
  - filtrado, 14, 16
  - geométrico, 14
  - híbridos, 14, 20, 29
  - heurísticos, 14
  - marginalización, **24**, 27
  - modelos estocásticos, 14, 15
  - ordenación, **33**, 34
  - paramétricos, 25, 29
  - procesamiento de señal, 14, 15
  - sintácticos, 14
  - umbralización, **27**, 29–31
- detección automática
  - de defectos, 9
  - de invernaderos, **51**, 57, 66, 70
- diagnóstico médico automático, 8, 12
- direccionalidad, 5
- discriminación
  - de texturas, 9, 13, 29, 46, 47, 49
  - poder, 15, 20, 22, 27, 33, 66, 69
  - preatentiva, 6
  - visual, 4, 5
- distancia de Manhattan, 59
- distribución
  - de Laplace, 32

- de patrones, 22, 23, 39
- de probabilidad conjunta, 17, 19, 20, 22, 24
- espacial, 1, 14, 19
- dureza, 5
- entrenamiento, 31, 33, 52, 54, 55, 58–60
- entropía, 17, 31, 36, **44**, 48, 70
- equivalencia
  - clase, 20, **23**, 30, 32, 33, 38, 43–45, 48, 70
  - relación, 18, 19, **22**, 23, 24, 70, 71
- escala, 2, 3, 5, 49, 53–55
- escuela de la Gestalt, 5
- espectro electromagnético, 13
- filtro
  - de Gabor, 7, 16
  - de Sobel, 36
  - laplaciano de la gaussiana, 35
- finura, 4
- forma, 1, 10
- frequency mosaic, *véase* CCR
- fuzzy c-means, 32
- gestión
  - automática de catálogos, 13
  - de residuos agrícolas, 12
  - del territorio, 12
- granularidad, 4
- grosor, 4, 5
- histograma de patrones, 17–19, **20**, 21, 22, 24, 25, 35, 36, 47, 58, 61, 70
  - concatenación, 26, 27, 30, 33, 34
  - marginal, 34
- identificación de texturas, **9**
- iluminación, 9
  - condiciones, 4, 52–55
  - dirección, 53, 54
- imagen
  - aérea, 12
  - acústica, 13
  - de satélite, 12, 38, 51, 52, **57**, 58, 61, 66, 70, 71
  - en color, 55, 57
  - no óptica, 13
  - pancromática, 57
- integración curvilínea, 15
- invarianza
  - a rotación, 25, 27, **36**, 37, 39
  - a simetría, 25
  - transformaciones monotónicas, 27, 48
- k-means, 38
- levantamiento de cartografía, 12
- máscaras de Laws, 15, 16
- macrotextura, 3, 54
- matrices de coocurrencia, 16, 24–27, 35, 36, 38, 66, 70
- microscopía electrónica, 13
- microtextura, 3, 14, 15, 35, 54
- modelos autorregresivos, 16
- monitorización de procesos, 8
- n-tuplas, 31, **33**, 34, 35, 38
- norma L1 de Minkowski, *véase* distancia de Manhattan
- orientación, 5, 6, 10, 49, 55
- p-gramas, 32
- patrones de textura, **19**, 20, 22, 23, 30, 43–48
  - equivalentes, 17, **20**, 21, 23, 25, 33, 35–37, 43, 47, 58, 61, 70
  - simétricos, 37
  - uniformes, **37**
- percepción
  - de la textura, 4, 6, 7, 69
  - preatentiva, 5
  - visual humana, 4, 5, 9, 23
- primitivas, 3, 6, 7, 10, 14, 35
- problemas canónicos, **8**, 9, 71
- procesamiento digital de imágenes, 1, 8, 12, 52
  - en tiempo real, 33, 38, 41, 46, 61
  - preprocesamiento, 35
- pronums, *véase* TU
- prospectrum, *véase* TS
- QuickBird, 57
- query by image, 9
- raw primal sketch, 7
- rayos

- gamma, 13
- X, 13
- reconocimiento de patrones, 31, 33
- redes neuronales, 31, 33, 38
- regularidad, 5
- resonancia magnética, 13
- robótica, 8, 17
  
- síntesis de texturas, **9**
- saturación, 5
- segmentación, **8**, 9, 12, 15, 51, 54, 66, 71
  - manual, 61
  - no supervisada, 9, 55
  - supervisada, 9, 55
- seguridad, 8, 12, 17
  - detección de caras, 13
  - identificación biométrica, 13
- sensibilidad
  - a muestras atípicas, **33**
  - al ruido, 27, 39
- shape from texture, **10**
- similitud
  - criterio, 8, 23, 59
  - medida, 30, 36
- similitud lineal, 5
- split-half, 59
- stratified sampling, 59
- suavidad, 4
  
- técnicas fractales, 14–16
- tasa de acierto, 16, 17, 55, **60**, 61, 63, 65, 67, 69, 71, 75
- teledetección, 8, 11, 17, 66, 70
- teselación de Voronoi, 38
- test de Wilcoxon, 63, 65, 71
- test suite, *véase* banco de pruebas
- texel, 3
- textón, 6, 7
- textura
  - en color, 31, 54, 57
  - en escala de grises, 31, 54
  - estacionaria, **19**, 52, 57, 58, 61, 66, 70, 71
- tomografía axial, 13
- transformada
  - Census, 31, 32
  - Rank, 34
  
- umbralización
  - binaria, 24, 27, 30, 31, 37, 41, 46, 70
  - borrosa, 39, **39**
  - isoentrópica, 31, 32
  - ternaria, 24, 27
- usos del suelo, 12
  
- visión
  - biológica, 4
  - espacial temprana, 7
  - por computador, 4, 7, 52, 69
  - preatentiva, 6
  - sistema humano, 1, 7, 8









