



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
POSGRADO EN CIENCIA E INGENIERÍA EN COMPUTACIÓN

ANÁLISIS DE LA DISTRIBUCIÓN DE COLOR Y
TEXTURA EN OBRAS DE ARTE.

T E S I S

QUE PARA OPTAR POR EL GRADO DE:
MAESTRO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

P R E S E N T A:
FAUSTO VINCENZO CARRILLO DE ALBORNOZ CARRANZA

Director de Tesis:
DR. JORGE ALBERTO MÁRQUEZ FLORES
Facultad de ciencias, UNAM

Ciudad Universitaria, CD. MX. Febrero, 2018



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Agradecimientos

Agradezco especialmente a mi padre Fausto y a mi madre Leticia por brindarme todo su apoyo y cariño incondicional, por confiar siempre en mí.

A mi hermana Andrea, por aconsejarme, apoyarme y darme ánimos en los momentos más complicados. Por ser la mejor hermana, gracias.

Al Dr. Jorge Márquez por la paciencia, la asesoría, los conocimientos y materiales que me brindó para realizar este trabajo de manera satisfactoria.

Gracias a Raúl, Jonathan, Fabián, y Cristóbal; amigos que muy pronto se convirtieron en mis hermanos, gracias a todos ustedes.

Agradezco al Posgrado de Ciencia e Ingeniería en Computación por permitirme realizar estudios de posgrado, a todos los profesores y personal del mismo por su apoyo, conocimiento, y paciencia.

A los miembros del jurado, los doctores Boris, Miguel, Patrice y Ernesto por el tiempo invertido en las correcciones de la tesis.

Agradezco enormemente a la Universidad Nacional Autónoma de México por todo el conocimiento y experiencias que me ha otorgado. Por todo eso y más, muchas gracias.

Muchas gracias a Maya por ser la mejor perrita del mundo, por levantarme el ánimo y siempre estar conmigo.

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca otorgada para realizar mis estudios de posgrado.

Índice general

Agradecimientos	III
Índice de Figuras	IX
1. Introducción	3
1.1. Antecedentes	3
1.2. Estado del arte	4
1.3. Justificación del problema	7
1.4. Objetivos	7
1.5. Contribución de la tesis	7
1.6. Estructura de la tesis	7
2. Pintores y obras estudiados	9
2.1. Leonardo Da Vinci (1452-1519)	9
2.1.1. Perspectiva	9
2.2. Salvador Dalí (1904-1989)	9
2.3. Diego Rivera (1886-1957)	10
2.4. Claude Monet (1840-1926)	10
2.5. Pablo Picasso (1881-1973)	10
2.6. Pierre-Auguste Renoir (1841-1919)	10
2.7. Vincent Van Gogh (1853-1890)	11
2.8. Adquisición de pinturas	11
2.8.1. Características de las pinturas	11
3. Herramientas para el análisis de Color	17
3.1. Antecedentes	17
3.2. Modelos de color	18
3.2.1. Modelo RGB	18
3.2.2. Modelo HSI	19
3.2.3. Conversión entre el modelo RGB y HSI	20
3.3. Análisis de componentes principales	21
3.3.1. Media, Varianza y desviación estándar	21
3.3.2. Covarianza	22
3.3.3. Matriz de covarianza	22
3.4. Histograma	23
3.4.1. Histograma en escala de grises	23
3.4.2. Histograma 3D	23

3.5.	Centro de masa de la distribución de color	24
3.5.1.	Tensor de Inercia	25
3.6.	Transformada de distancia	25
3.6.1.	Definición	26
3.6.2.	Transformada de distancia con signo	27
3.6.3.	Aplicaciones	28
3.7.	Transformaciones geométricas en tres dimensiones	28
3.7.1.	Traslación	28
3.7.2.	Cambio de escala	29
3.7.3.	Rotación	29
3.8.	Dimensión fractal	35
3.8.1.	Algoritmo Box-counting	36
3.9.	Voxelización	37
3.10.	Algoritmo Flood-fill	38
4.	Herramientas para el análisis de texturas	41
4.1.	Antecedentes	41
4.1.1.	Métodos de análisis de texturas	41
4.2.	Matriz de co-ocurrencia de niveles de gris	42
4.2.1.	GLCM normalizada	43
4.2.2.	GLCM simétrica	43
4.2.3.	Descriptores estadísticos obtenidos a partir de la GLCM	43
4.3.	Patrones binarios locales	46
4.3.1.	Patrones binarios locales uniformes	47
4.3.2.	Patrones binarios locales dominantes	48
5.	Metodología	49
5.1.	Normalización de medias y desviación estándar	49
5.1.1.	Pseudocódigo para ajustar la media y desviación estándar de un conjunto de Imágenes	49
5.2.	Generación del elipsoide que mejor ajusta la distribución de color	53
5.2.1.	Visualización de la distribución de color	53
5.2.2.	Cálculo y visualización de ejes principales	53
5.2.3.	Factores de escala para el elipsoide	53
5.2.4.	Visualización del elipsoide que mejor ajusta y ejes principales	54
5.3.	Mapa de color de la superficie generada a partir de la distribución de color	59
5.3.1.	Voxelizado del elipsoide	59
5.3.2.	Campo de distancia	61
5.3.3.	Cálculo del mapa de color	61
5.3.4.	Características asociadas a la distribución de color y al elipsoide ajustado	67
5.3.5.	Histograma de 64 colores	68
5.3.6.	Brillo y oscuridad en una pintura	69
5.3.7.	Error cuadrático medio	69
5.4.	Imágenes basadas en los descriptores de GLCM	70

5.4.1.	Recuantización	71
5.4.2.	Cálculo de la imagen basada en los descriptores de la GLCM	74
5.5.	Imágenes paramétricas	77
5.6.	Histogramas basados en patrones binarios locales	80
5.6.1.	Histograma de patrones binarios locales	80
5.6.2.	Histograma de patrones binarios locales uniformes	82
5.6.3.	Histograma de patrones binarios locales dominantes	84
6.	Experimentos y Resultados	87
6.1.	Resultados análisis de color	88
6.1.1.	Descriptores promedio	88
6.1.2.	Colores más usados	93
6.1.3.	Brillo y oscuridad de una pintura	98
6.2.	Resultados análisis textural	109
6.2.1.	Matriz de Co-ocurrencia de niveles de gris	109
6.2.2.	Imágenes paramétricas	116
6.2.3.	Patrones binarios locales	123
6.2.4.	Patrones binarios locales dominantes	125
7.	conclusiones	127
7.1.	Trabajo a futuro	128
	Apéndices	129
A.		131
A.1.	Movimientos artísticos	131
A.1.1.	Renacimiento (1400-1600)	131
A.1.2.	Surrealismo (1924-1966)	132
A.1.3.	Cubismo (1907-1922)	133
A.1.4.	Impresionismo	134
B.		135
B.0.1.	Cambio de la media de un conjunto de datos	137
C.		139
C.1.	Iluminación y sombreado	139
C.1.1.	Modelo de iluminación	139
C.1.2.	Modelos de Sombreado	142
C.1.3.	Flat shading	142
C.1.4.	Gouraud shading	142
C.1.5.	Phong shading	143
D.		145
	Bibliografía	155

Índice de figuras

3.1.	Prisma de Newton. Imagen tomada de (Pérez, 2015).	17
3.2.	Cubo que representa al espacio RGB. Imagen tomada de (Pacifci, 2012)	19
3.3.	Espacio HSI. Imagen tomada de (Blotta et al., 2011).	20
3.4.	Imagen en escala de grises e histograma asociado. Histograma generado utilizando el software ImageJ .	23
3.5.	Imagen a color e histograma 3D asociado. Imagen generada utilizando el software ImageJ y el <i>plug-in</i> Color Inspector 3D .	24
3.6.	a) Imagen binaria. (b) Transformada de distancia. Muestra las distancias en enteros al pixel 0 más cercano. Imagen Tomada de (Fabbri et al., 2008).	26
3.7.	Ejemplo de la transformada de distancia con signo. Imagen Tomada de (Yan and Kassim, 2004).	27
3.8.	Ejemplo de la traslación de un objeto en 3D. Imagen tomada de (Medellin, n.d.).	29
3.9.	Ejemplo del cambio de escala de un objeto en 3D. Imagen tomada de (Medellin, n.d.).	30
3.10.	Traslación del eje arbitrario para que pase por el origen del sistema de coordenadas.	32
3.11.	Rotación de \vec{u} para hacerlo coincidir con el plano XZ.	33
3.12.	Rotación de \vec{v} para hacerlo coincidir con el plano XZ.	34
3.13.	Algoritmo de box-counting. Imagen tomada de (Lenon et al., 2015).	37
3.14.	Modelo voxelizado, interior vacío (izquierda). Modelo voxelizado, interior sólido (derecha). Imagen tomada de (Schwarz and Seidel, 2010).	38
3.15.	Tipos de vecindad que se pueden considerar en un pixel. Imágenes tomadas de (Bhatia, 2008).	39
3.16.	Resultado de aplicar el algoritmo Flood-fill a una región.	39
4.1.	Tres matrices de co-ocurrencia para una imagen en niveles de gris. Imagen tomada de (Shapiro and Stockman, 2001).	43
4.2.	Cálculo de la etiqueta para un pixel central, tomando en cuenta a sus ocho vecinos. Imagen tomada de (Wagner, n.d.).	46
4.3.	Patrones uniformes considerados para ULBP considerando 8 pixeles vecinos. Imagen tomada de (Pietikäinen et al., 2011).	47
5.1.	Pinturas originales.	52
5.2.		52
5.3.		54

5.4.	Elipsoide centrado en el origen.	55
5.5.	58
5.6.	60
5.7.	Superficie generada a partir de la distribución de color utilizando el software Amira.	63
5.8.	<i>Gala contemplando al Mediterráneo</i> (1976).	65
5.9.	66
5.10.	67
5.11.	División del espacio RGB en 64 regiones.	69
5.12.	Descripción detallada de la división del espacio RGB en 64 regiones.	69
5.13.	Cálculo de una imagen basada en los descriptores asociados a la GLCM. Imagen tomada de (?).	71
5.14.	72
5.15.	73
5.16.	Pintura original e imágenes de textura obtenidas a partir de los descriptores calculados a la GLCM.	76
5.17.	Pintura original e imágenes de textura obtenidas a partir de los descriptores calculados a la GLCM.	77
5.18.	Pintura original y texturas a color obtenidas de la combinación de disimilitud, entropía y homogeneidad.	79
5.19.	Monalisa e histograma de LBP asociado. Para calcular este histograma se consideraron 8 vecinos con un radio=1.	82
5.20.	Monalisa e histograma de ULBP asociado.	84
6.1.	Gráfica de cajas asociada al parámetro esfericidad.	90
6.2.	Gráfica de cajas asociada a la dimensión fractal.	90
6.3.	Gráfica de cajas asociada a la distancia promedio al centroide promedio.	91
6.4.	Gráfica de cajas asociada al ángulo de desviación promedio respecto al eje principal promedio.	92
6.5.	Gráfica de cajas asociada a RMSE	93
6.6.	Histogramas de las imágenes pertenecientes a Aleatorias.	94
6.7.	Histogramas de las pinturas de Salvador Dalí.	94
6.8.	Histogramas de las pinturas de Leonardo Da Vinci.	95
6.9.	Histogramas de las pinturas de Diego Rivera.	95
6.10.	Histogramas de pinturas de los diferentes artistas estudiados.	96
6.11.	Histogramas de pinturas de Claude Monet.	96
6.12.	Histogramas de pinturas de Pablo Picasso.	97
6.13.	Histogramas de pinturas de Pierre-Auguste Renoir.	97
6.14.	Histogramas de pinturas de Vincent Van Gogh.	98
6.15.	Histograma del parámetro <i>value</i> de Aleatorias.	100
6.16.	Histograma del parámetro <i>value</i> de las pinturas de Salvador Dalí.	101
6.17.	Histograma del parámetro <i>value</i> de las pinturas Leonardo Da Vinci.	102
6.18.	Histograma del parámetro <i>value</i> de las pinturas de Diego Rivera.	103
6.19.	Histograma del parámetro <i>value</i> de las pinturas de Claude Monet.	104
6.20.	Histograma del parámetro <i>value</i> de las pinturas de Pablo Picasso.	105
6.21.	Histograma del parámetro <i>value</i> de las pinturas de Combinadas	106

6.22. Histograma del parámetro <i>value</i> de las pinturas de Pierre-Auguste Renoir.	107
6.23. Histograma del parámetro <i>value</i> de las pinturas de Vincent Van Gogh.	108
6.24. Diagrama de cajas asociada al descriptor ASM.	111
6.25. Gráfica de cajas asociada al descriptor correlación.	112
6.26. Diagrama de cajas asociada al descriptor contraste.	113
6.27. Diagrama de cajas asociado al descriptor homogeneidad.	114
6.28. Diagrama de cajas asociada al descriptor disimilitud.	115
6.29. Diagrama de cajas asociada al descriptor entropía.	116
6.30. Distribuciones de imágenes paramétricas utilizando los descriptores disimilitud, homogeneidad y entropía.	117
6.31. Distribuciones de imágenes paramétricas utilizando los descriptores disimilitud, homogeneidad y entropía.	118
6.32. Distribuciones de imágenes paramétricas utilizando los descriptores ASM, correlación y contraste.	119
6.33. Distribuciones de imágenes paramétricas utilizando los descriptores ASM, correlación y contraste.	120
6.34. Distribuciones de imágenes paramétricas utilizando los descriptores ASM, disimilitud y entropía.	121
6.35. Distribuciones de imágenes paramétricas utilizando los descriptores ASM, disimilitud y entropía.	122
6.36. Gráfica que muestra los valores promedio al comparar histogramas utilizando ULBP y desviaciones estándar de la comparación.	124
6.37. Gráfica que muestra los valores promedio al comparar histogramas utilizando ULBP y desviaciones estándar de la comparación.	124
6.38. Diagrama de cajas asociado al número de patrones dominantes obtenidos para cada pintura analizada.	126
C.1. Reflexión difusa. Imagen tomada de (Throne, n.d.).	140
C.2. Reflexión especular. Imagen tomada de (Throne, n.d.).	141
C.3. Modelo de Phong que resulta de combinar las 3 componentes del modelo de iluminación (ambiental, difusa y especular). Imagen tomada de (Throne, n.d.).	141
C.4. Flat shading aplicado a un modelo 3D. Imagen tomada de (<i>Shading</i> , n.d.).	142
C.5. Gouraud shading aplicado a un modelo 3D. Imagen tomada de (<i>Shading</i> , n.d.).	143
C.6. Phong shading aplicado a un modelo 3D. Imagen tomada de (<i>Shading</i> , n.d.).	143

1 Capítulo 1

2 Introducción

3 En el siguiente trabajo se presentan las herramientas que fueron desarrolladas
4 para analizar las pinturas de artistas como **Leonardo Da Vinci**, **Salvador Dalí**,
5 **Diego Rivera**, **Claude Monet**, **Pablo Picasso**, **Pierre-Auguste Renoir** y, **Vin-**
6 **cent Van Gogh**, a partir de la distribución de color y textura.

7 Utilizando análisis de componentes principales, y con ayuda de *OpenGL*, se cal-
8 culan y visualizan los ejes principales, así como el elipsoide que mejor ajusta a cada
9 distribución de color. Además, se muestra también, la superficie generada a partir
10 de la distribución de color, a la cual se le asigna un mapa de color que varía entre
11 color azul y rojo, dependiendo de su posición respecto al elipsoide que mejor ajusta.

12 En el apartado de *análisis de textura* se calculó la matriz de co-ocurrencia de
13 niveles de gris y, a partir de los descriptores de **Haralick** se generaron imágenes
14 paramétricas, las cuales recibieron tratamiento similar al de la distribución de color.
15 Aprovechando el cálculo de algunos de los descriptores de **Haralick**, se evaluó qué
16 tan presentes se encuentran en cada pintor estudiado.

17 Para finalizar, a cada pintura se le calculó el histograma de patrones binarios
18 locales (LBP por sus siglas en inglés) para tratar de determinar si existen similitudes
19 entre pinturas pertenecientes a un mismo pintor y, al mismo tiempo, observar las
20 diferencias entre pinturas de artistas diferentes.

21 1.1. Antecedentes

22 El arte ha estado presente en la vida del ser humano desde tiempos prehistóricos.
23 El hombre de las cavernas expresaba y, de cierta manera, documentaba sus ideas,
24 experiencias y emociones a través escenarios simples o complejos que pintaba en
25 los muros de las cavernas. Con el paso del tiempo, las técnicas y estilos de pintura,
26 los materiales utilizados y los lugares donde los artistas plasmaban sus ideas fueron
27 cambiando. Tablas, telas, paredes y muros; cualquier lugar funcionaba como lienzo
28 para que los pintores pudiesen expresar y plasmar sus obras. Como ejemplo se tiene
29 el techo de la Capilla Sixtina pintado por **Miguel Ángel**; los muros de Palacio
30 Nacional en la Ciudad de México pintados por **Diego Rivera** e incluso, los *graffitis*
31 callejeros pueden ser considerados una expresión artística.

32 Con la disponibilidad de grandes colecciones *en línea*, algunos investigadores se
33 han interesado en aplicar técnicas y metodologías científicas, particularmente de

34 procesamiento digital de imágenes y algunos métodos estadísticos, que les permitan
35 tratar de entender y cuantificar la estructura y composición de las pinturas. Lo
36 anterior con el objetivo de reducir la brecha existente entre el arte y la ciencia.

37 Por otra parte, con dichas galerías disponibles, surge la necesidad de desarrollar
38 sistemas multimedia para archivar y consultar las colecciones, para que las galerías
39 en línea puedan mostrar pinturas contemporáneas, además de desarrollar sistemas
40 de recomendación automatizada que puedan recuperar pinturas con características
41 similares para exhibirlas a compradores potenciales. Lo anterior enaltece la necesidad
42 de investigar métricas de similitud visual entre pinturas digitalizadas (Saleh and
43 Elgammal, 2015).

44 Para analizar y estudiar los elementos de las artes visuales, se han abordado
45 distintos enfoques. Éstos incluyen tratar de identificar a los pintores, autenticación
46 de pinturas, así como encontrar conexiones significativas entre diferentes artistas
47 (Cetinic and Grgic, 2013).

48 La clasificación y análisis de pinturas se encomienda normalmente a expertos en
49 arte aunque trabajos recientes han propuesto la idea de automatizar dicho proceso.

50 Los expertos en arte clasifican las pinturas de acuerdo a un conjunto de atributos
51 conocidos como estilo de pintura¹.

52 Las pinturas pueden analizarse de acuerdo a dos tipos de características (Widjaja
53 et al., 2003)

54 **Semánticas:** Iconografía y tema.

55 **Sintácticas:** Color, textura y composición en general.

56 La mejor forma para iniciar el análisis de una obra de arte desde la perspectiva
57 computacional es concentrándose en elementos como color, textura y forma (Cetinic
58 and Grgic, 2013)

59 1.2. Estado del arte

60 En (Saleh and Elgammal, 2015) se evalúan métricas de aprendizaje que permitan
61 determinar el estilo, género de una pintura e, incluso al artista. La metodología
62 consistió en extraer características de las pinturas tales como bordes e identificar
63 objetos en la pintura (características visuales). Posteriormente asociaron métricas de
64 aprendizaje optimizado a cada uno de los elementos por determinar (artista, género,
65 estilo). Con la información obtenida de las características y las métricas obtenidas se
66 generó un vector de características final que fue utilizado para entrenar clasificadores
67 como **máquinas de soporte vectorial** y **redes neuronales convolucionales**
68 para realizar la clasificación.

69 (Puthenputhussery and Liu, 2016) motivados por campos como Visión Compu-
70 tacional y Psicología Cognitiva, desarrollaron una serie de características para ana-
71 lizar obras de arte desde diferentes perspectivas, a su vez, complementarias. En su

¹Combinación de características técnicas, composicionales e iconográficas que proporcionan a la pintura cierto carácter y permiten atribuirla a una escuela particular o periodo (Widjaja et al., 2003)

72 trabajo codificaron un descriptor que incorporaba información local y espacial so-
73 bre el color, así como información sobre la intensidad relativa y orientación de su
74 gradiente.

75 Para resolver dicha problemática, desarrollaron diversos vectores de rasgos, basándo-
76 se en el vector de Fisher y combinándolo con descriptores de SIFT, DAISY y Weber.
77 Con dichos vectores lograron obtener resultados satisfactorios para clasificar pintu-
78 ras, descubrir la influencia del artista y de estilo.

79 (Condorovici et al., 2013) propone utilizar histogramas de color en 3D, los cuales
80 permiten caracterizar la paleta de color de las pinturas, y una serie de filtros de
81 Gabor para caracterizar el nivel de detalle. Con los rasgos obtenidos y el apoyo de
82 clasificadores logró reconocer pinturas pertenecientes a ciertos autores.

83 (Culjak et al., 2011) considera 6 géneros artísticos: *realismo*, *cubismo*, *impre-*
84 *sionismo*, *fovismo*, *puntillismo* y *arte naïf* (Naive Art). Su objetivo principal es
85 encontrar las características que permitan mejorar la clasificación de géneros sin to-
86 mar en cuenta la semántica de la pintura. Dichas características las obtiene de la
87 distribución de color de la pintura y del análisis textural realizado a la misma. Para
88 el análisis de color, genera y utiliza el histograma de color. De dicho histograma ob-
89 tiene máximos locales, máximos absolutos así como razones o tasas de concentración
90 de píxeles que le permiten caracterizar qué tan oscura o brillante es una pintura, ya
91 que de acuerdo a lo que se menciona en su artículo, una de las principales diferencias
92 entre los distintos géneros artísticos se encuentra en la luminosidad de las pinturas.
93 En el análisis textural (Culjak et al., 2011) utilizó filtros como *blur filters*, *sharpen*
94 *filters* y filtros detectores de bordes. De la misma forma que en el análisis de color,
95 generó tasas o razones de aparición de bordes en las pinturas, que utilizó como un
96 descriptor más de la pintura. Finalmente, para clasificar las pinturas (Culjak et al.,
97 2011) utilizó los clasificadores incluidos en el software WEKA ².

98 En (Zujovic et al., 2009) se clasificaron pinturas por género artístico. La meto-
99 dología propuesta consiste en dos etapas: **extracción de características** y **cla-**
100 **sificación**. Para caracterizar el color de la pintura, genera histogramas para cada
101 componente en el espacio **HSV**. Utiliza también, **filtros de Canny** para detectar
102 bordes bajo diferentes umbrales, debido a que ciertos estilos poseen bordes sutiles,
103 como el *impresionismo* y otros estilos, tales como el arte pop, presentan bordes pro-
104 nunciados. Similar a (Culjak et al., 2011), (Zujovic et al., 2009) genera una razón o
105 proporción de bordes dentro de una pintura. Esta razón es igual al número de píxeles
106 que pertenecen a un borde entre el total de píxeles que componen a la pintura.

107 Para concluir el análisis, utiliza la información obtenida de los histogramas y la
108 proporción de bordes para alimentar clasificadores provistos por WEKA.

109 (Marchenko et al., 2005) utilizó un enfoque diferente a los revisados previamente
110 para analizar el color de las pinturas. Extrae regiones homogéneas y utiliza técnicas
111 de *Machine Learning* y procesamiento digital de imágenes para caracterizar regiones
112 de la pintura en términos de conceptos de color artísticos como **temperatura**, **pale-**
113 **ta de colores** y **contraste**. Divide su análisis en 3 etapas: Segmentación, análisis de
114 conceptos color a nivel región y análisis de conceptos de color para toda la imagen.

115 Primero segmenta la imagen, debido a que para analizar temperatura y con-
116 traste necesita tomar en cuenta la localización espacial de los colores en la pintura.

²<https://www.cs.waikato.ac.nz/ml/weka/>

117 Posteriormente, analiza regiones y obtiene características geométricas tales como
 118 normalización de la región, el rectángulo mínimo que la engloba, el centro y la ex-
 119 centricidad. Con ayuda de una **máquina de soporte vectorial probabilística**
 120 asigna a cada región cierta temperatura, ya sea neutral, fría o cálida. En el caso del
 121 **contraste**, modela dos regiones como un conjunto de pares de color basándose en el
 122 color predominante de cada región. Con lo anterior calcula 4 tipos de **contraste** los
 123 cuales son: contraste de valor, de temperatura, complementario y, claro-oscuro.

124 Finalmente, para caracterizar la pintura bajo dichos conceptos, toma en cuenta
 125 los valores calculados para cada región para determinar el valor de la imagen en
 126 general.

127 Muchos trabajos han presentado estudios referentes a la clasificación de pintu-
 128 ras por **género**, sin embargo, éstos realmente clasifican pinturas por movimiento
 129 artístico o estilo. El término **género** se refiere al contenido que presenta cada pintu-
 130 ra, como puede ser historia, religión, paisajes y retratos (Cetinic and Grgic, 2016).
 131 El trabajo de (Cetinic and Grgic, 2016) se enfoca en clasificar pinturas de acuerdo
 132 al género.

133 Para lograr dicho objetivo, (Cetinic and Grgic, 2016) basó su análisis en cinco
 134 descriptores: **SIFT** (Scale Invariant Feature Transform), características basadas en
 135 **redes neuronales convolucionales**, **GIST**, **HOG** (Histogram of Oriented Gra-
 136 dients) y la **mtariz de co-ocurrencia de niveles de gris** (GLCM por sus siglas
 137 en inglés). Al final, descubrió que las características basadas en **redes neuronales**
 138 **convolucionales** mostraron mejor desempeño sobre el resto de los descriptores para
 139 la tarea de clasificar pinturas de acuerdo a su género.

140 En (Yang and Xu, 2011) se propone un algoritmo que permite distinguir con
 141 precisión entre el estilo *Sumi e*³ y arte extranjero. El método se basa en 3 ca-
 142 racterísticas de las pinturas: contraste de color, espacios en blanco en la pintura y
 143 uniformidad de la iluminación.

144 (Cetinic and Grgic, 2013) propone un método para reconocer pintores de una obra
 145 de arte concentrándose solamente en los elementos cuantificables de las pinturas.
 146 Dichos elementos se clasifican en tres tipos:

147 **Características estadísticas:** Media, varianza, rango de intensidades de niveles
 148 de gris, kurtosis, energía y entropía.

149 **Características de color:** Histograma en HSV y medidas estadísticas que puedan
 150 extraerse de dicho histograma.

151 **Textura:** GLCM (Gray-Level Co-Occurrence Matrix), detección y proporción de
 152 bordes, *wavelets*.

153 Para la clasificación (Cetinic and Grgic, 2013) utilizó cinco clasificadores utilizando
 154 la herramienta WEKA. Los clasificadores utilizados fueron: Perceptrón multicapa,
 155 SMO (sequential minimal optimization for support vectorial machines), *Naive Bayes*,
 156 *Random Forest* y *Ada Boost M1*. Al final, reporta un 75 por ciento de precisión en
 157 sus resultados.

³Técnica japonesa de dibujo en tinta.

158 (Kim et al., 2014) estudia el color y las estructuras espaciales de pinturas a lo
159 largo de diez periodos históricos entre los que destacan el periodo *medieval*, *renaci-*
160 *miento*, *manerismo*, *barroco*, *neoclasicismo*, romanticismo y realismo. En el estudio,
161 analizan el uso de cada color, la variedad de colores utilizados, y consideran qué tan
162 rugoso o suave es la imagen respecto al brillo de la misma. Finalmente miden la
163 dimensión fractal de los colores que se utilizan en las pinturas de cada periodo.

164 **1.3. Justificación del problema**

165 La utilidad de realizar un estudio como el que se propone, es mostrar al público
166 en general información cuantitativa sobre el comportamiento del color y la textura
167 en alguna o varias pinturas. Asimismo, dicha información puede complementar el
168 análisis hecho por algún experto en arte y tal vez, ayudar a tener mejor entendimiento
169 de la composición de la pintura. Por otra parte, este tipo de aplicaciones servirán
170 como base para el desarrollo de sistemas en línea que permitan recuperar pinturas
171 con características similares, ya sea en color y/o textura, que puedan interesarle al
172 público en general o a compradores potenciales.

173 Otra aplicación es caracterizar la influencia posible en ciertas obras de arte con-
174 temporáneas e inclusive apoyar estudios de autenticidad y autoría. Además, el análi-
175 sis textural per-se tiene aplicaciones en terrenos distintos al de las obras de arte, como
176 en ciencias del suelo, metalurgia y biomedicina.

177 **1.4. Objetivos**

178 Diseñar y programar herramientas que permitan analizar de manera cuantitativa
179 el color y textura de diversas obras de arte. Tratar caracterizar el estilo de cada pintor
180 seleccionado analizando algunas de sus pinturas. Comparar los resultados obtenidos
181 entre los diversos autores estudiados. Observar diferencias y semejanzas entre los
182 estilos de pintura.

183 **1.5. Contribución de la tesis**

184 Desarrollo de herramientas de análisis y visualización para obtener información
185 cuantitativa de una o varias obras de arte, con la finalidad de mostrar que es posible
186 analizarlas utilizando herramientas científicas. Asimismo, encontrar y mostrar las
187 técnicas o metodologías más eficaces para efectuar dicho análisis y sentar las bases
188 para estudios más profundos.

189 **1.6. Estructura de la tesis**

190 En el capítulo 2 se presenta información relevante de los pintores como lugar de
191 nacimiento, estilo de pintura y, corriente artística a la que pertenecieron.

192 En el capítulo 3 se describen de manera detallada los conceptos, técnicas y,
193 herramientas utilizadas para efectuar el análisis de la distribución de color de las
194 pinturas.

195 El capítulo 4 presenta conceptos, técnicas y metodologías necesarias para realizar
196 el análisis de texturas a las pinturas elegidas.

197 En el capítulo 5 se muestra la metodología y las tareas que se llevaron a cabo
198 para analizar la textura y la distribución de color de las pinturas.

199 En el capítulo 6 se discuten los resultados obtenidos para cada pintor y, se ex-
200 ponen tablas y gráficas que permiten comparar los resultados.

201 En el apéndice A se exponen antecedentes y contexto histórico desde el punto de
202 vista artístico. Se describen de manera concisa las características de las corrientes
203 artísticas a las que pertenecieron cada uno de los pintores estudiados.

204 En el apéndice B se describe el proceso para cambiar la media y desviación
205 estándar de un conjunto de datos así como algunas propiedades útiles.

206 El apéndice C se describen de manera breve los modelos de iluminación utilizados
207 en graficación por computadora, así como las técnicas de sombreado.

208 Capítulo 2

209 Pintores y obras estudiados

210 2.1. Leonardo Da Vinci (1452-1519)

211 Fue entrenado como pintor y escultor en Florencia, Italia, dentro del taller de
212 Andrea del Verrocchio (1435-1488). Como pintor, dibujaba lo que observaba en el
213 mundo que lo rodeaba incluyendo anatomía humana, vida silvestre, el movimien-
214 to del agua y, el vuelo de las aves (Bambach, 2002). Motivado por la curiosidad,
215 Leonardo trataba constantemente de explicar lo que veía.

216 2.1.1. Perspectiva

217 Leonardo se dio cuenta que una forma de pintar escenas de manera realista
218 era observar con mucho cuidado como los animales, personas y, paisajes realmente
219 lucían. Solía escribir notas detalladas sobre sus observaciones e incluía bocetos de
220 las cosas que observó a lo largo de su vida.

221 Leonardo vivió durante el período de *Renacimiento* en Italia. Fue en este periodo
222 que arquitectos y artistas investigaban como dibujar objetos tridimensionales en una
223 superficie plana. Comenzaron a pensar en la pintura como una **ventana abierta**
224 a través de la cual el observador podía ver el mundo. Se desarrolló un sistema de
225 reglas matemáticas, conocidas como **perspectiva lineal**, para ayudar a los pintores
226 a pintar de forma realista. Leonardo aprendió dichas reglas de perspectiva y practicó
227 utilizando la ventana como un artefacto que le permitió dibujar la perspectiva de
228 los objetos de manera correcta mientras era aprendiz en el taller de Andrea del
229 Verrocchio (*Da Vinci - The Artist*, n.d.).

230 2.2. Salvador Dalí (1904-1989)

231 Salvador Dalí nació el 11 de mayo de 1904, en el pequeño pueblo de Figueras,
232 una región de Cataluña, España. El trabajo de Dalí explora 3 temas: El universo y
233 la sensación humana, simbolismo sexual, y pictografía. Salvador Dalí es considerado
234 como uno de los grandes representantes de *Surrealismo*¹ (*Salvador Dalí*, n.d.).

¹Movimiento del siglo XX que procuraba liberar el potencial creativo del inconsciente a través de imágenes extrañas y oníricas.

2.3. Diego Rivera (1886-1957)

Nació el 8 de diciembre de 1886 en Guanajuato, Guanajuato.

Fue considerado uno de los grandes artistas en el ámbito mundial. Rivera ingresó en la Academia de San Carlos a los diez años de edad. Entre 1913 y 1917 creó un importante número de obras cubistas, aunque también exploró otros estilos pictóricos. En 1921 se integró al programa cultural del gobierno de México, encabezado por José Vasconcelos.

Con el tema *La creación*, en 1922, Rivera creó su primer mural en la Escuela Nacional Preparatoria. Con el paso del tiempo crearía 15 murales más, realizados en México y Estados Unidos. De su obra destacan su magna producción mural, sus más de tres mil cuadros, centenares de dibujos, obras gráficas e ilustraciones (*Diego Rivera*, n.d.).

2.4. Claude Monet (1840-1926)

Claude Monet nació el 14 de noviembre de 1840, en París, Francia. Es conocido por sus aportaciones al movimiento artístico denominado como *Impresionismo*. En las composiciones de este período, Monet aplica el color con pinceladas cortas y vigorosas. Lo anterior, debido a la espontaneidad e inmediatez que exige la pintura al aire libre a la hora de capturar una impresión de la naturaleza (*Claude Monet. Obra y biografía*, n.d.).

2.5. Pablo Picasso (1881-1973)

Pablo Picasso nació el 25 de octubre de 1881 en Málaga España. Junto con Georges Braque, fue uno de los creadores del *Cubismo*. En 1896 ingresa en la Real Academia de Bellas Artes, y allí comienza su formación artística dentro del realismo académico. A partir de 1900, realiza una serie de obras que constituyen un corpus homogéneo que será calificado más tarde como **etapa azul**, caracterizada por el alargamiento del cano, la utilización de gamas frías de color y el tono melancólico y ascético de las Figuras. Aproximadamente en 1904, inicia la denominada **etapa rosa**, en la que desarrolla composiciones con formas clásicas y colores más cálidos. En 1907 realiza *Les demoiselles d'Ávignon*, obra considerada como el origen del *cubismo*, en la que plantea una nueva relación entre volumen, espacio, Figura y fondo.

2.6. Pierre-Auguste Renoir (1841-1919)

Nació el 25 de febrero de 1841 en Limoges, Francia. Renoir fue una de las Figuras principales del movimiento impresionista. Desde el año 1861, asistió a las clases de dibujo de Charles Gleyre, y finalmente fue admitido en la École des Beaux-Arts en 1862. Sin embargo, continuó ligado al estudio de Gleyre, donde conicidió con Claude Monet, Alfred Sisley y Frédéric Bazille. Pasó temporadas junto a Monet

271 en Argenteuil ², donde ambos realizaron paisajes que se convertirían en ejemplos
272 paradigmáticos del estilo impresionista (*Pierre-Auguste Renoir*, n.d.).

273 2.7. Vincent Van Gogh (1853-1890)

274 Nació el 30 de marzo de 1853 en Groot-Zundert, Holanda. Fue entre 1860 y 1880
275 que decidió convertirse en artista. En 1886 fue a París, para unirse con su hermano
276 Theo. En París, conoció a Pissarro, Monet y Gauguin. A partir de ese momento,
277 Van Gogh comenzó a dar más luz a su paleta, bastante oscura, y a pintar con cortes
278 impresionistas. Las obras más finas de Van Gogh fueron producidas en menos de
279 tres años por una técnica que crecía con el transcurso del tiempo. El artista estaba
280 absorto completamente en el esfuerzo para explicar su lucha contra la locura o en
281 la comprensión de la esencia espiritual de hombre y naturaleza (*Vincent van Gogh:*
282 *Biografía*, n.d.).

283 2.8. Adquisición de pinturas

284 Las pinturas que fueron estudiadas al realizar este trabajo fueron obtenidas de
285 diversas fuentes electrónicas, las cuales se mencionan a continuación:

- 286 ■ <http://art-gallery.com/>
- 287 ■ <http://art-monet.com/>
- 288 ■ <http://art-picasso.com/>
- 289 ■ <http://art-renoir.com/>
- 290 ■ <https://www.dalipaintings.com/>
- 291 ■ <https://www.diegorivera.org/>
- 292 ■ <https://www.leonardodavinci.net/>

293 2.8.1. Características de las pinturas

294 Las pinturas elegidas se encuentran en formato **.jpg**. El tamaño de las pinturas
295 puede variar según el sitio de donde fue descargada. Sin embargo, se trataron de
296 elegir a las pinturas con mayor resolución, teniendo al menos 500 pixeles por lado.

297 Debido a la dificultad para encontrar las versiones digitalizadas de las pinturas
298 en buena calidad, la cantidad de pinturas utilizadas para estudiar a cada pintor
299 puede variar. Se consideraron al menos diez pinturas por autor. A continuación se
300 mencionan, clasificadas por autor, las pinturas que fueron utilizadas en este trabajo:

² Comuna de Francia situada en el departamento de Valle del Oise y de la región de Isla de Francia.

301 **Salvador Dalí**

- 302 1. *Bacchanale (1939)*.
- 303 2. *Cristo de San Juan de la Cruz (1951)* .
- 304 3. *Crucifixión (1954)*.
- 305 4. *Sueño causado por el vuelo de una abeja alrededor de una granada un segundo*
306 *antes de despertar (1944)*.
- 307 5. *Gala contemplando el Mediterráneo (1976)*.
- 308 6. *Niño geopolítico observando el nacimiento del nuevo hombre (1943)*.
- 309 7. *Cabeza rafaelesca estallando (1951)*.
- 310 8. *La tentación de San Antonio (1946)*.
- 311 9. *La última cena (1955)*.
- 312 10. *Metamorfosis de Narciso (1937)*.
- 313 11. *El sueño (1937)*.
- 314 12. *La araña de la noche (1940)*.
- 315 13. *Cisnes que se reflejan como elefantes (1937)*.
- 316 14. *Los elefantes (1948)*.
- 317 15. *El gran masturbador (1929)*.
- 318 16. *Cisnes que se reflejan como elefantes (1937)*.
- 319 17. *La gabineta antropomórfica (1936)*.
- 320 18. *Jirafa en llamas (1937)*.
- 321 19. *La desintegración de la persistencia de la memoria (1952-1954)*.
- 322 20. *La Madonna de Port Lligat (1950)*.
- 323 21. *Reloj blando en el momento de su primera explosión (1955)*.
- 324 22. *Pesca del Atún (1967)*.

325 **Leonardo Da Vinci**

- 326 1. *Baco (1510-1515)*.
- 327 2. *Retrato de Ginebra de Benci (1474-1476)*.
- 328 3. *Cabeza de muchacha (1508)*.
- 329 4. *La dama del armiño (1490)*.
- 330 5. *Leda y el cisne (1515-1520)*.
- 331 6. *Madonna Litta (1490)*.
- 332 7. *Virgen de la rueca (1499-1507)*.
- 333 8. *La Gioconda (1503-1519)*.
- 334 9. *San Juan Bautista (1508-1513)*.
- 335 10. *Anunciación (1472)*.
- 336 11. *La última cena (1495-1498)*.
- 337 12. *La Virgen, el Niño Jesús y Santa Ana (1510-1513)*

338 **Diego Rivera**

- 339 1. *Zapata líder Agrario (1931)*.
- 340 2. *Cruzando la barranca (1930)*.
- 341 3. *El Cargador de Flores (1935)*.
- 342 4. *Festival de las flores (1925)*.
- 343 5. *Vendedora de flores (1941)*.
- 344 6. *Fondos congelados (1931)*.
- 345 7. *Guerrero indio (1931)*.
- 346 8. *Jacques Lipchitz (1914)*.
- 347 9. *Hombre en la encrucijada (1933)*.
- 348 10. *Desnudo con alcatraces (1944)*.
- 349 11. *Retrato de Lupe Marín (1938)*.
- 350 12. *Retrato de Natasha Gelman (1943)*.
- 351 13. *Desnudo con girasoles (1946)*.
- 352 14. *La abundante tierra (1946)*.

353 **Claude Monet**

- 354 1. *A corner of the studio (1861).*
- 355 2. *Boatyard near Honfleur (1864).*
- 356 3. *By the sea (1864).*
- 357 4. *Farm near Honfleur (1864).*
- 358 5. *Hauling a Boat Ashore, Honfleur (1864).*
- 359 6. *Lighthouse at the Hospice (1864) .*
- 360 7. *Road to the Saint-Simeon farm (1864).*
- 361 8. *Seacoast at Saint-Adresse, Sunset (1864).*
- 362 9. *Spring Flowers (1864).*
- 363 10. *Still life with bottles (1863).*
- 364 11. *Trophies of the hunt (1862).*

365 **Pablo Picasso**

- 366 1. *A rooster (1938).*
- 367 2. *Great bather reading (1937).*
- 368 3. *Head of a Woman No. 1, Portrait of Dora Maar .*
- 369 4. *Head of a Woman No. 2, Portrait of Dora Maar (1939).*
- 370 5. *Head (1938).*
- 371 6. *Leaning woman (1938).*
- 372 7. *Man with a straw hat (1938).*
- 373 8. *Minotaur is wounded (1937).*
- 374 9. *Portrait of Dora Maar (1937).*
- 375 10. *Portrait of Dora Maar (1937).*
- 376 11. *Portrait of Dora Maar (1937).*
- 377 12. *Portrait de Lee Miller en Arlésienne (1937).*
- 378 13. *Portrait of Marie-Thérèse Walter with garland (1937).*
- 379 14. *Portrait of Marie-Thérèse Walter (1937).*
- 380 15. *Portrait of Marie-Thérèse Walter (1937).*

381 16. *Portrait of Marie-Thérèse Walter (1937)*.

382 17. *Portrait of Nusch Éluard (1937)*.

383 18. *The imploring (1937)*.

384 19. *Untitled (1937)*.

385 20. *Untitled (1937)*.

386 **Pierre-Auguste Renoir**

387 1. *Colonel Barton Howard Jenks (1865)*.

388 2. *Crown of roses (1858)*.

389 3. *Diana the Huntress (1867)*.

390 4. *Lisa Sewing (1866)*.

391 5. *Portrait of Mademoiselle Sicotg*.

392 6. *Reclining nude (1863)*.

393 7. *Mademoiselle Romaine Lacaux (1864)*.

394 8. *Sleeping Cat (1862)*.

395 9. *Spring flowers (864)*.

396 10. *The artist's mother (1860)*.

397 11. *The Inn Of Mother Anthony (1866)*.

398 12. *The Painter Jules Le Coeur Walking His Dogs in the Forest of Fontainebleau*
399 *(1866)*.

400 13. *The Return of the Boating Party (1862)*.

401 14. *Two figures in a landscape (1866)*.

402 15. *Portrait of William Sisley (1864)*.

403 **Vincent Van Gogh**

404 1. *Garden with courting couples: square Saint-Pierre*.

405 2. *The garden of the hospital (1889)*.

406 3. *Gate in the Paris Ramparts (1887)*.

407 4. *Irises (1890)*.

408 5. *Landscape with a Stack of Peat and Farmhouses (1883)*.

- 409 6. *Old Vineyard with Peasant Woman (1890).*
- 410 7. *Pollard Willow (1882).*
- 411 8. *Sunflowers (1888).*
- 412 9. *The bedroom (1889).*
- 413 10. *The potato eaters (1885).*
- 414 11. *The sower (1888).*
- 415 12. *Tree roots (1890).*
- 416 13. *View from Vincent's Studio (1886).*
- 417 14. *Weaver (1884).*
- 418 15. *Wheatfield with a Reaper (1889).*
- 419 16. *Wheatfield under Thunderclouds (1890)*

420 Capítulo 3

421 Herramientas para el análisis de 422 Color

423 En este capítulo se presentan antecedentes, fundamentos y herramientas que
424 permitirán, más adelante, entender la metodología utilizada para caracterizar una
425 pintura a través de su color.

426 3.1. Antecedentes

427 En 1666, Sir Isaac Newton descubrió que cuando un rayo de luz solar atraviesa
428 un prisma de cristal, el haz de luz resultante no era blanco si no que consistía en un
429 espectro de colores que iban desde violeta a un extremo y rojo al otro tal como se
430 observa en la Figura 3.1.



Figura 3.1: Prisma de Newton. Imagen tomada de (Pérez, 2015).

431 Los colores que los humanos y algunos animales perciben en un objeto están
432 determinados por la luz que dicho objeto refleja. Por ejemplo, los objetos verdes
433 reflejan luz con longitud de onda entre 500 a 570 nm mientras que absorben la
434 mayor parte de la energía de otras longitudes de onda.

435 Los conos son sensores en el ojo sensibles al color. Éstos pueden ser divididos en
436 tres categorías sensitivas: luz roja, luz verde y luz azul. De acuerdo a estas caracte-
437 rísticas de absorción del ojo humano, los colores son percibidos como una combi-
438 nación de los llamados colores primarios rojo, verde y azul.

439 Las características utilizadas generalmente para distinguir un color de otro son
440 el brillo (*brightness*), la saturación (*saturation*) y tono o matiz (*hue*). El brillo se
441 refiere a la noción de intensidad. El matiz representa el color dominante percibido
442 por el observador. La saturación se refiere a la pureza o la cantidad de luz blanca
443 que contiene dicho color.

444 3.2. Modelos de color

445 El propósito de un modelo de color es facilitar la especificación de colores en algún
446 estándar. Un modelo de color es una especificación de un sistema de coordenadas y
447 un subespacio dentro de dicho sistema donde cada color se representa por un solo
448 punto.

449 3.2.1. Modelo RGB

450 Este modelo está basado en el sistema de coordenadas cartesiano. Los colores
451 primarios rojo, verde y azul, se encuentran en tres esquinas del cubo que se muestra
452 en la Figura 3.2; los colores secundarios cyan, magenta y amarillo se encuentran en
453 las tres esquinas restantes; el color negro se encuentra en el origen del sistema de
454 coordenadas mientras que el color blanco está en la esquina más alejada del origen.
455 En este modelo, la escala de grises ¹ se extiende desde negro hasta blanco a lo largo
456 de la línea que une esos dos puntos. Los diferentes colores en este modelo son los
457 puntos que están dentro o sobre el cubo.

¹Puntos con el mismo valor en los ejes R, G, B

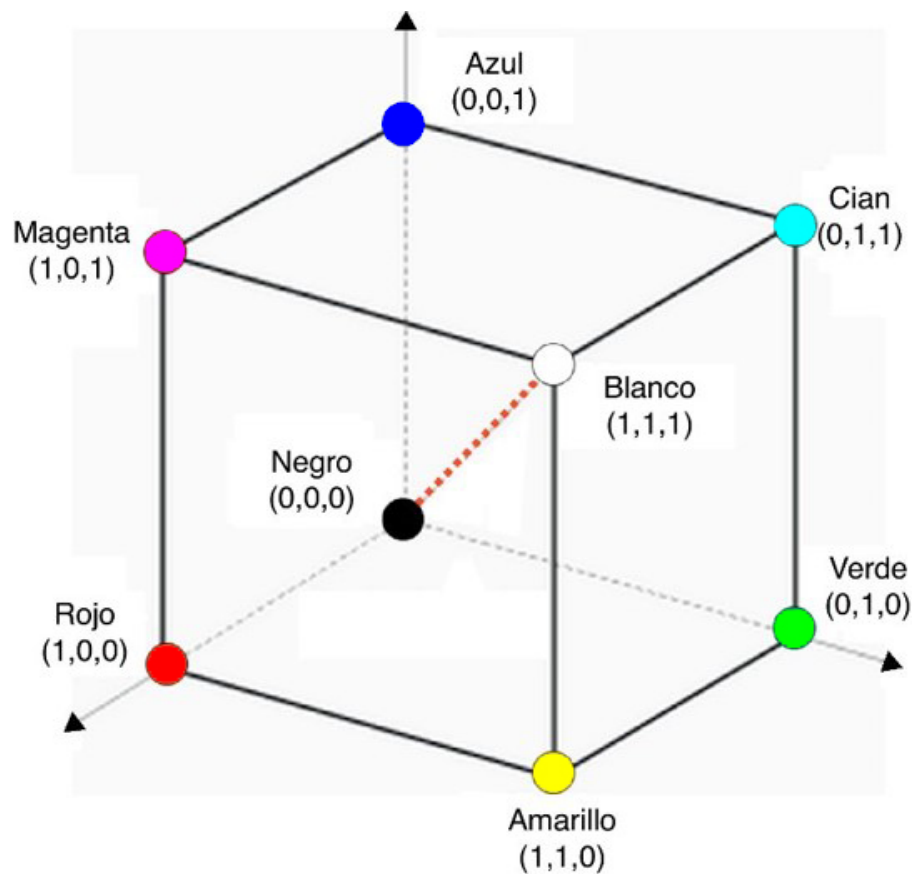


Figura 3.2: Cubo que representa al espacio RGB. Imagen tomada de (Pacifici, 2012)

458 3.2.2. Modelo HSI

459 Cuando los seres humanos perciben el color de un objeto, lo describen a través de
 460 su **matiz** (*hue*), **saturación**, (*saturation*) y **brillo** (*brightness*). Como se mencionó
 461 anteriormente, el matiz es un atributo que describe un color puro (amarillo puro,
 462 naranja puro, rojo puro, etc); la saturación se refiere a la cantidad de luz blanca
 463 que tiene el color puro. Por otro lado, el brillo es un descriptor subjetivo que es casi
 464 imposible de medir. Sin embargo, involucra la noción acromática de intensidad, la
 465 cual es uno de los descriptores más útiles de las imágenes monocromáticas.

466 El modelo HSI separa la componente de intensidad de las componentes que tienen
 467 información sobre el color. El espacio HSI está representado por un eje vertical
 468 asociado a la intensidad y el conjunto de puntos que representan al color se encuentra
 469 en planos perpendiculares a dicho eje. La Figura 3.3 muestra la representación gráfica
 470 del espacio HSI.




Figura 3.3: Espacio HSI. Imagen tomada de (Blotta et al., 2011).

471 3.2.3. Conversión entre el modelo RGB y HSI

472 Dado cierto punto $p(r,g,b)$ en el espacio RGB, este se relaciona con el sistema
 473 HSI en una forma similar, aunque no idéntica, a la forma en que las coordenadas
 474 cilíndricas se relacionan al sistema cartesiano. Por lo anterior, la transformación entre
 475 un sistema y otro se puede considerar como una rotación del cubo RGB, seguido
 476 por una transformación del cubo rotado a las coordenadas cilíndricas (modificadas)
 477 HSI (Ledley et al., 1990)

478 Dada una imagen en RGB, la componente H de cada pixel RGB se obtiene usando
 479 la siguiente ecuación:

$$H = \begin{cases} \theta & \text{si } B \leq G \\ 360 - \theta & \text{si } B > G \end{cases} \quad (3.1)$$

480 Donde :

$$\theta = \arccos \left(\frac{\frac{1}{2}[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{\frac{1}{2}}} \right) \quad (3.2)$$

El componente de la saturación está dada por:

$$S = 1 - \frac{3}{R + G + B}(\min(R, G, B)) \quad (3.3)$$

La componente de intensidad está dada por:

$$I = \frac{1}{3}(R + G + B) \quad (3.4)$$

481 3.3. Análisis de componentes principales

482 Análisis de componentes principales (PCA por sus siglas en inglés) es una técnica
483 estadística que analiza la estructura de la covarianza de datos multivariados. A su
484 vez, determina las direcciones a lo largo de las cuales la variación de los datos ocurre y
485 su respectiva importancia. El primer componente principal otorga la dirección donde
486 se observa la varianza máxima de datos. El segundo componente principal, describe
487 la dirección de la segunda máxima varianza que se presenta en el conjunto de datos,
488 además, es ortogonal al vector que representa la dirección del primer componente
489 principal (Wijewickrema and Paplinski, 2005).

490 En (Smith, 2002) PCA se define como un procedimiento matemático ideado para
491 reemplazar cierto número de variables correlacionadas con un nuevo conjunto de
492 variables que no estén correlacionadas. Dicho cambio de variables se logra al aplicar
493 una transformación ortogonal. Para realizar análisis de componente principales, es
494 necesario efectuar los siguientes pasos:

- 495 1. Calcular media y varianza para cada variable o dimensión.
- 496 2. Calcular la matriz de covarianza.
- 497 3. Calcular los *eigenvectores* y *eigenvalores* correspondientes a la matriz de co-
498 varianza.

499 3.3.1. Media, Varianza y desviación estándar

500 De acuerdo a (Muñoz, 2004), las medidas de dispersión central de un conjunto
501 de datos se definen como sigue:

Media

$$\bar{X} = \sum_{i=1}^N \frac{x_i}{N} \quad (3.5)$$

Varianza

$$\text{var}(X) = \sum_{i=1}^N \frac{(x_i - \bar{X})^2}{N} \quad (3.6)$$

502 **Desviación estándar** La desviación estándar se calcula a partir de la varianza,
503 y se define como sigue:

$$\sigma = \sqrt{\text{var}(X)} \quad (3.7)$$

504 3.3.2. Covarianza

La covarianza entre dos variables Aleatorias o conjuntos de datos y (Muñoz, 2004) la define de la siguiente manera:

$$\text{covar}(X, Y) = \sum_{i=1}^N \frac{(x_i - \bar{X})(y_i - \bar{Y})}{N} \quad (3.8)$$

505 Donde X y Y son dos variables Aleatorias o conjuntos de datos.

506 3.3.3. Matriz de covarianza

507 La matriz de covarianza es una representación ordenada de las varianzas y cova-
508 rianzas de las dimensiones o variables aleatorias estudiadas (Ojeda, 2007).

Entonces, la matriz de covarianza para un conjunto de datos con n dimensiones se define como:

$$C^{n \times n} = (c_{i,j}, c_{i,j} = \text{cov}(\text{Dim}_i, \text{Dim}_j)) \quad (3.9)$$

Donde $C^{n \times n}$ es una matriz con n columnas y n renglones.

Cada elemento de la matriz resulta de calcular la covarianza entre dos dimensiones. Por ejemplo, el elemento (2,3) de la matriz es el resultado de calcular la covarianza entre la segunda y tercera dimensión del conjunto de datos.

Ejemplo:

Supongamos un conjunto de tres dimensiones X , Y y Z . La matriz de covarianza tendrá entonces 3 dimensiones y sus elementos son los siguientes:

$$C = \begin{pmatrix} \text{cov}(X, X) & \text{cov}(X, Y) & \text{cov}(X, Z) \\ \text{cov}(Y, X) & \text{cov}(Y, Y) & \text{cov}(Y, Z) \\ \text{cov}(Z, X) & \text{cov}(Z, Y) & \text{cov}(Z, Z) \end{pmatrix} \quad (3.10)$$

509 Eigenvectores y Eigenvalores

510 Conocidos también como valores y vectores propios, los *eigenvalores* y *eigenvec-*
511 *tores* son útiles en diversas aplicaciones de física e ingeniería tales como: circuitos
512 eléctricos, sistemas mecánicos, entre otros.

513

514 *Definición:* Sea una matriz $A \in \mathbb{R}^{n \times n}$

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \cdots & a_{1n} \\ a_{21} & a_{22} & a_{23} & \cdots & a_{2n} \\ a_{31} & a_{32} & a_{33} & \cdots & a_{3n} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ a_{n1} & a_{n2} & a_{n3} & \cdots & a_{nn} \end{bmatrix} \quad (3.11)$$

515 Un escalar λ se llama **eigenvalor** de A si existe un vector X distinto de cero, tal
 516 que $AX = \lambda X$. Tal vector X es el **eigenvector** asociado a A (Poole, 2011).

517 3.4. Histograma

518 El histograma de una imagen con niveles de intensidad que van de $[0, L-1]$ es una
 519 función discreta $h(r_k) = n_k$, donde r_k es el k -ésimo valor de intensidad y n_k es
 520 el número de píxeles en la imagen con esa intensidad (González and Woods, 2007).
 521 Suele ser común normalizar los histogramas dividiendo cada uno de sus componentes
 522 entre el total de píxeles existentes en la imagen.

523 3.4.1. Histograma en escala de grises

524 En una imagen de 8 bits existen 256 diferentes intensidades. El histograma aso-
 525 ciado a una imagen con dichas características, mostrará la frecuencia en que ocurren
 526 ciertos valores de intensidad dentro de la imagen. La Figura 3.4 muestra una imagen
 527 en escala de grises y el histograma asociado.

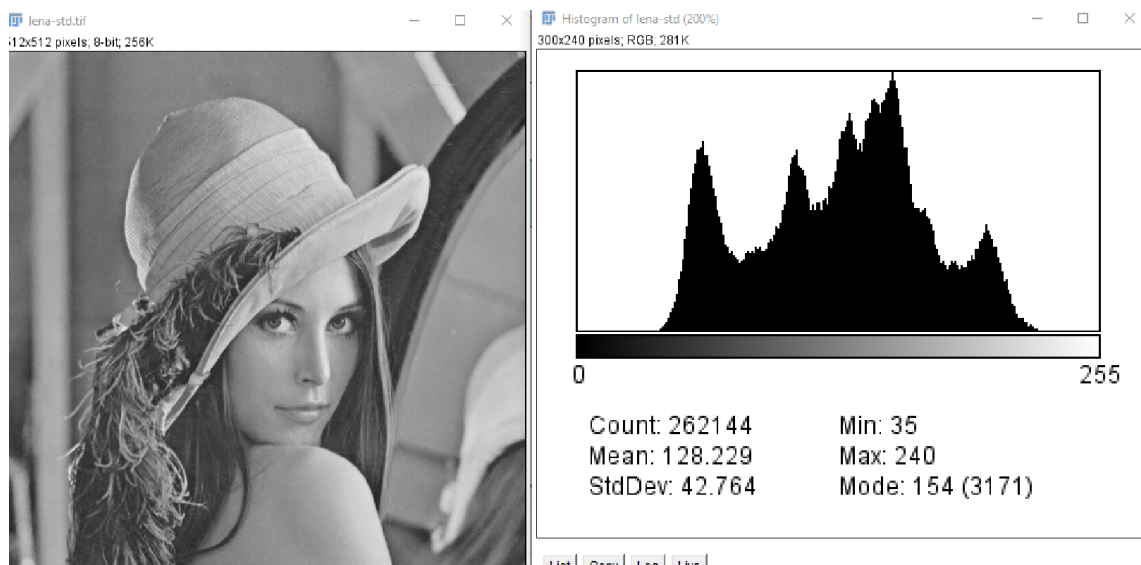


Figura 3.4: Imagen en escala de grises e histograma asociado. Histograma generado utilizando el software **ImageJ**.

528 3.4.2. Histograma 3D

529 Un histograma 3D o histograma de color se puede generar a partir de una imagen
 530 a color (32 bits). Se tienen 3 ejes que representan a cada componente de color, en
 531 este caso en el espacio RGB. Se consideran píxeles iguales a aquellos que tienen los
 532 mismos valores en cada una de las componentes. La Figura 3.5 muestra una imagen
 533 a color y el histograma 3D de la misma.




Figura 3.5: Imagen a color e histograma 3D asociado. Imagen generada utilizando el software **ImageJ** y el *plug-in* **Color Inspector 3D**.

534 El histograma 3D será de utilidad para visualizar la distribución de color en el es-
 535 pacio RGB. También es necesario para obtener el **centro de masa** de la distribución
 536 de color así como el tensor de inercia para efectuar el **análisis de componentes**
 537 **principales**.

538 3.5. Centro de masa de la distribución de color

El centro de masa en dinámica de partículas, es un punto que se mueve como si fuera una partícula de masa igual a la masa total del sistema. En (Knudsen and Hjorth, 2000) el centro de masa de un sistema de partículas se define como:

$$CM = \frac{\sum_{i=1}^N m_i r_i}{M} \quad (3.12)$$

539 donde m_i y r_i son la masa y el vector de posición de la i -ésima partícula, y
 540 $M = \sum_i m_i$ es la masa total del sistema.

Considerando a la distribución de color de una pintura en el espacio RGB similar a un sistema de partículas, donde el total de ocurrencias de un pixel se considera como la masa m_i de la partícula, la posición r_i está dada por las coordenadas del pixel en el espacio RGB y, la masa total M del sistema es el total de pixeles contenidos en la imagen. Entonces, el centro de masa de la distribución de color se define como:

$$(r_c, g_c, b_c) = \frac{\sum_{(r,g,b) \in VOI} (r, g, b) (Histo(r, g, b))}{\sum_{(r,g,b) \in VOI} Histo(r, g, b)} \quad (3.13)$$

541 Donde (r, g, b) es el color RGB, $Histo(r, g, b)$ es el número de ocurrencias de ese
 542 color y VOI es el volumen de interés.

543 3.5.1. Tensor de Inercia

El tensor de inercia proporciona una idea general de cómo está distribuida la masa en un un cuerpo rígido (Peraire and Widnall, 2008).

El tensor de inercia alrededor del centro de masa de la distribución de color en el espacio RGB se define mediante la siguiente matriz:

$$C = \begin{pmatrix} I_{rr} & -I_{rg} & -I_{rb} \\ -I_{gr} & I_{gg} & -I_{gb} \\ -I_{br} & -I_{bg} & I_{bb} \end{pmatrix} \quad (3.14)$$

544 Donde:

$$I_{rr} = \frac{1}{\text{card}(VOI)} \sum_{r,g,b \in VOI} \text{Histo}(r, g, b) ((g - g_c)^2 + (b - b_c)^2) \quad (3.15)$$

$$I_{rg} = \frac{1}{\text{card}(VOI)} \sum_{r,g,b \in VOI} \text{Histo}(r, g, b) ((r - r_c)^2 + (b - b_c)^2) \quad (3.16)$$

$$I_{rb} = \frac{1}{\text{card}(VOI)} \sum_{r,g,b \in VOI} \text{Histo}(r, g, b) ((g - g_c)^2 + (r - r_c)^2) \quad (3.17)$$

$$I_{rg} = I_{gr} = \frac{1}{\text{card}(VOI)} \sum_{r,g,b \in VOI} \text{Histo}(r, g, b) (r - r_c)(g - g_c) \quad (3.18)$$

$$I_{rb} = I_{br} = \frac{1}{\text{card}(VOI)} \sum_{r,g,b \in VOI} \text{Histo}(r, g, b) (r - r_c)(b - b_c) \quad (3.19)$$

$$I_{gb} = I_{bg} = \frac{1}{\text{card}(VOI)} \sum_{r,g,b \in VOI} \text{Histo}(r, g, b) (g - g_c)(b - b_c) \quad (3.20)$$

545 Donde (r_c, g_c, b_c) son las coordenadas del centro de masa de la distribución de
546 color y $\text{card}(VOI)$ es la cardinalidad.

547 Para realizar el análisis de componentes principales a la distribución de color, el
548 tensor de inercia tomará el lugar de la matriz de covarianza. Lo anterior tiene como
549 objetivo otorgar mayor peso a los pixeles con mayor número de ocurrencias.

550 3.6. Transformada de distancia

551 El campo de distancia o transformada de distancia (DT) es un operador geométri-
552 co fundamental con grandes aplicaciones en campos como graficación por compu-
553 tadora, visión computacional, análisis de forma, reconocimiento de patrones, y geo-
554 metría computacional (Fabbri et al., 2008).

555 3.6.1. Definición

Sea $I : \Omega \subset \mathbb{Z}^2 \rightarrow \{0, 1\}$ una imagen binaria donde el dominio Ω es convexo y, en particular, $\Omega = \{1, \dots, n\} \times \{1, \dots, n\}$, a menos que se diga lo contrario. Por convención, el valor 0 se asocia a negro y el valor 1 se asocia a blanco. Tenemos entonces un objeto \mathcal{O} representado por todos los pixeles blancos como sigue:

$$\mathcal{O} = \{p \in \Omega \mid I(p) = 1\}$$

556 El conjunto \mathcal{O} se conoce como objeto o frente (*foreground*) y se compone de
 557 cualquier subconjunto del dominio de la imagen, incluyendo conjuntos disjuntos.
 558 Por otro lado, los elementos de su complemento, \mathcal{O}^c el conjunto de pixeles negros en
 559 Ω se conocen como fondo (*background*).

Definición La transformada de distancia (DT) es aquella transformación que genera un mapa D cuyo valor en cada pixel p es la distancia más corta de dicho pixel a \mathcal{O}^c (Fabbri et al., 2008):

$$D(p) := \min\{d(p, q) \mid q \in \mathcal{O}^c\} = \min\{d(p, q) \mid I(q) = 0\} \quad (3.21)$$

D se conoce como el *mapa de distancia* de I . Se asume que \mathcal{O}^c contiene al menos un pixel.

La distancia $d(p, q)$, generalmente la distancia euclidiana, está dada por:

$$d(p, q) = \sqrt{(p_x - q_x)^2 + (p_y - q_y)^2} \quad (3.22)$$

560 En la Figura 3.6 a) se muestra una imagen binaria. En 3.6 b) se muestra el mapa de distancia de dicha imagen.




Figura 3.6: a) Imagen binaria. (b) Transformada de distancia. Muestra las distancias en enteros al pixel 0 más cercano. Imagen Tomada de (Fabbri et al., 2008).

3.6.2. Transformada de distancia con signo

Dada una imagen binaria que consiste en uno o más objetos y un fondo, se define a la transformada de distancia con signo como una transformación que asigna a cada pixel la distancia de ese pixel particular al pixel con valor cero más cercano. El signo de la distancia asignada indica si el punto está fuera (positivo) o dentro (negativo) del objeto (Grevera, 2004).

La Figura 3.7 muestra un ejemplo de una transformada de distancia con signo.

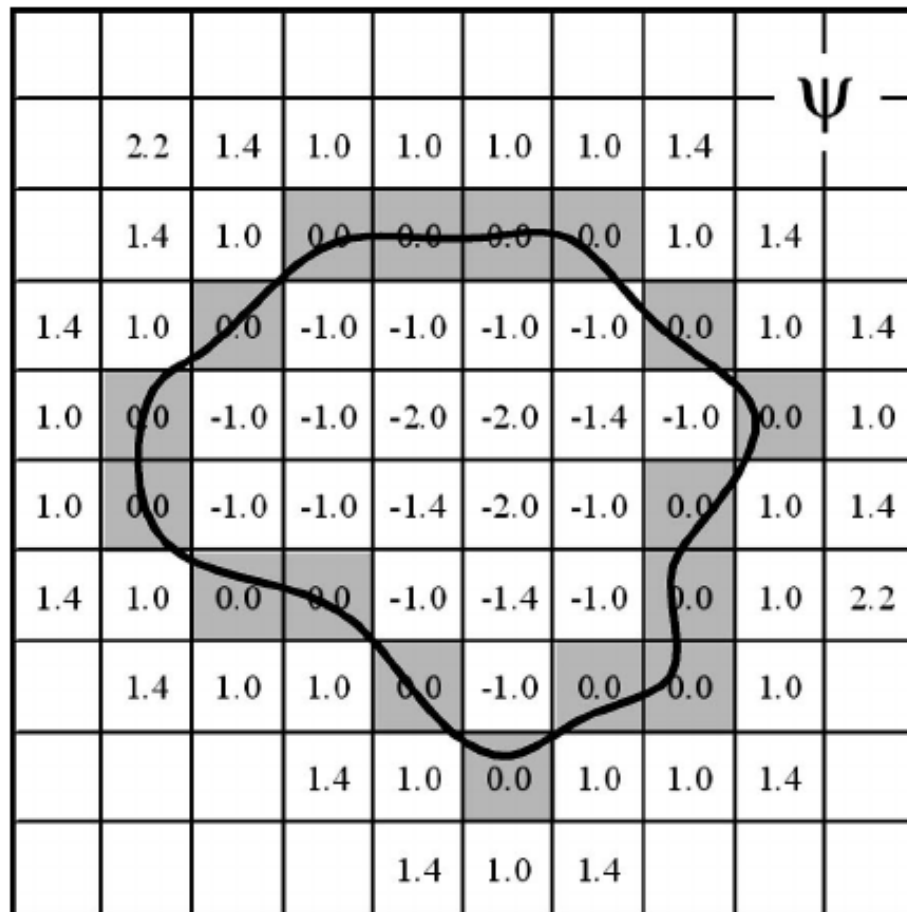


Figura 3.7: Ejemplo de la transformada de distancia con signo. Imagen Tomada de (Yan and Kassim, 2004).

569 3.6.3. Aplicaciones

570 La transformada de distancia (DT) tiene numerosas aplicaciones algunas de las
571 cuales se mencionan a continuación:

- 572 ■ Separación de objetos que se traslapan.
- 573 ■ Esqueletonización (*Skeletonization*) o transformada del eje medio (*medial axis*
574 *transform*).
- 575 ■ Diagramas de Voronoi.
- 576 ■ Dimensión fractal.
- 577 ■ Uso de *SKIZ* (*Skeleton by influence zones*) en la navegación de robots. Permi-
578 ten encontrar la ruta más corta de un lugar a otro sorteando obstáculos.
- 579 ■ Análisis de datos multidimensionales (clasificación y clustering).
- 580 ■ Registro (alineación generalizada) de objetos en dos y tres dimensiones.
- 581 ■ Cálculo del espesor de un cráneo o de la corteza cerebral, radio local de redes
582 arteriovenosas y ancho local de surcos y de circunvoluciones.

583 La transformada de distancia con signo, en la versión de tres dimensiones, será
584 de utilidad para generar el **mapa de color** de la superficie generada a partir de la
585 distribución de color de una pintura. Con su ayuda, se podrá conocer la distancia que
586 existe entre un punto de dicha superficie y elipsoide que mejor ajusta la distribución.
587 Lo anterior permitirá asignar cierto color a la superficie dependiendo de la distancia
588 encontrada.

589 3.7. Transformaciones geométricas en tres dimen- 590 siones

591 Para poder orientar correctamente el **elipsoide que mejor ajusta** respecto
592 al sistema de ejes principales de la distribución de color, es necesario conocer las
593 transformaciones geométricas que se enumeran a continuación:

594 3.7.1. Traslación

595 La traslación consiste en mover un objeto (línea, punto, polígono) en el espacio 3D
596 una distancia determinada. La matriz que define la traslación en 3D es la siguiente:

$$T = \begin{pmatrix} 1 & 0 & 0 & x \\ 0 & 1 & 0 & y \\ 0 & 0 & 1 & z \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.23)$$

597 Donde x, y, z son las distancias que se trasladará dicho objeto en la dirección de
598 cada uno de los ejes coordenados.

599 En la Figura 3.8 se muestra de manera gráfica el procedimiento de traslación de
un objeto en el espacio tridimensional.




Figura 3.8: Ejemplo de la traslación de un objeto en 3D. Imagen tomada de (Medellin, n.d.).

600

601 3.7.2. Cambio de escala

602 El escalamiento o cambio de escala consiste en cambiar el tamaño de un objeto en
603 el espacio 3D en una o varias direcciones. La matriz que define esta transformación
604 es la siguiente:

$$T = \begin{pmatrix} S_x & 0 & 0 & 0 \\ 0 & S_y & 0 & 0 \\ 0 & 0 & S_z & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.24)$$

605 En la figura 3.9 se muestra un ejemplo del proceso de escalamiento de un objeto
606 en el espacio tridimensional.

607 3.7.3. Rotación

608 Las matrices de rotación en 3D representan una rotación en sentido antihorario,
609 cierto ángulo θ alrededor de un eje fijo. De manera general, una matriz de rotación
610 en tres dimensiones puede denotarse como $R(\hat{n}, \theta)$. Donde \hat{n} es el eje de rotación y
611 θ el ángulo. Por convención, una rotación positiva corresponde a una rotación en
612 sentido antihorario (*Three-Dimensional Rotation Matrices*, 2012).




Figura 3.9: Ejemplo del cambio de escala de un objeto en 3D. Imagen tomada de (Medellin, n.d.).

613 Propiedades (Gruber, 2000)

- 614 1. Las matrices de rotación son ortogonales, es decir, $RR^T = I$ donde R^T es la
 615 matriz transpuesta de R e I es la matriz identidad. Es conveniente mencionar,
 616 que el producto punto de cualquier par de filas es igual a 0.
- 617 2. R está normalizada. Los cuadrados de los elementos de cualquier fila o columna
 618 suman un total de 1.

619 Rotación respecto al eje X

620 La rotación de uno o más puntos alrededor del eje X se define a través de la
 621 siguiente matriz:

$$R_x = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos(\alpha) & \sin(\alpha) & 0 \\ 0 & -\sin(\alpha) & \cos(\alpha) & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.25)$$

622 Sea p un punto cualquiera en el espacio 3D con coordenadas x_p, y_p, z_p . Para rotar
 623 a p cierto ángulo α alrededor del eje X, se multiplica a p por la matriz R_x como
 624 sigue.

$P' = R_x P$ donde P' es el punto P rotado y P puede expresarse en forma de

vector columna como sigue:

$$p = \begin{pmatrix} p_x \\ p_y \\ p_z \\ 1 \end{pmatrix} \quad (3.26)$$

625 El mismo proceso de rotación de puntos puede aplicarse con las matrices de
626 rotación respecto al eje Y y al eje Z

627 Rotación respecto al eje Y

La matriz que describe la rotación respecto al eje coordenado Y es la siguiente:

$$R_y = \begin{pmatrix} \cos(\alpha) & 0 & -\sin(\alpha) & 0 \\ 0 & 1 & 0 & 0 \\ \sin(\alpha) & 0 & \cos(\alpha) & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.27)$$

628 Rotación respecto al eje Z

Matriz que describe la rotación respecto al eje coordenado Z:

$$R_z = \begin{pmatrix} \cos(\alpha) & \sin(\alpha) & 0 & 0 \\ -\sin(\alpha) & \cos(\alpha) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.28)$$

629 Rotación respecto a un eje arbitrario (Kovacs, 2012)

630 Para rotar un objeto o una serie de puntos alrededor de un eje arbitrario, diferente
631 a cualquiera de los ejes coordenados, es necesario seguir el procedimiento que se
632 describe a continuación:

- 633 1. Trasladar el objeto de forma que el eje de giro pase por el origen del sistema
634 de coordenadas. Sean $P(x, y, z)$ y $Q(x_1, y_1, z_1)$ dos puntos que pertenecen al
635 eje de giro \vec{v} y sea \vec{u} el vector unitario que tiene la dirección de \vec{v} . Se aplicara
636 una traslación $T(-x, -y, -z)$ para que el eje pase justamente por el origen del
637 sistema de coordenadas.
- 638 2. Girar el objeto de tal manera que dicho eje coincida con alguno de los ejes
639 coordenados.
- 640 3. Realizar el giro θ deseado.
- 641 4. Utilizar las matrices de giro inversas, y en orden inverso a como se realizo en
642 el punto número 2, para devolver el eje de giro a su orientación original.
- 643 5. Aplicar una transformación de traslación inversa a la utilizada en primer lugar,
644 para devolver el eje de giro, y al objeto, a su posición original.

Traslación del eje de giro Se debe trasladar el eje de giro y hacerlo pasar por el origen del sistema de coordenadas. Para efectuar la traslación, se define la siguiente matriz:

$$T = \begin{pmatrix} 1 & 0 & 0 & -x \\ 0 & 1 & 0 & -y \\ 0 & 0 & 1 & -z \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.29)$$




Figura 3.10: Traslación del eje arbitrario para que pase por el origen del sistema de coordenadas.

645 La Figura 3.10 ilustra la traslación del eje de giro y el vector unitario \vec{u} asociado.

646 **Alinear el eje de giro con uno de los ejes coordenados** Después de realizar
647 la traslación, se debe alinear el eje de giro \vec{u} con uno de los ejes coordenados. En
648 este caso se alinearán a \vec{u} con el eje coordenado Z.

649 El proceso anterior se divide en dos partes:

650 a) Girar a \vec{u} alrededor del eje coordenado X hasta que coincida con el plano XZ.

La Figura 3.11 muestra a $\vec{u}(a, b, c)$ y a $\vec{u}'(0, b, c)$ que es la proyección de \vec{u} sobre el plano YZ. Se observa que girar a \vec{u} alrededor del eje X hasta que coincida con el plano XZ requiere el mismo ángulo φ que girar a \vec{u}' hasta que coincida con el eje Z. De la Figura 3.11 se puede observar también que $\|\vec{u}\| = d$. Donde d se define de la siguiente manera:

$$d = \sqrt{b^2 + c^2} \quad (3.30)$$




Figura 3.11: Rotación de \vec{u} para hacerlo coincidir con el plano XZ.

También se concluye a partir de la Figura 3.11 que $\cos(\varphi) = \frac{c}{\|\vec{u}'\|} = \frac{c}{d}$ y $\sin(\varphi) = \frac{b}{d}$. por lo tanto, la matriz de rotación respecto al eje X resulta de la siguiente forma:

$$G_x = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & \frac{c}{d} & \frac{b}{d} & 0 \\ 0 & -\frac{b}{d} & \frac{c}{d} & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.31)$$

651 Finalmente, al aplicar la matriz G_x a \vec{u} , este se encontrará contenido en el plano
652 XZ.

653 b) Girar a \vec{u} respecto al eje coordenado Y hasta que coincida con el eje Z. El \vec{u} que
654 ahora se encuentra en el plano XZ, deberá ser girado alrededor del eje coordenado
655 Y hasta que coincida con el eje coordenado Z. Debido a que el giro a realizarse,
656 es en sentido horario, se considera un giro negativo.

En la Figura 3.12 se aprecia a $\vec{u}(a, 0, h)$ tras aplicar la primera rotación (respecto al eje coordenado X), donde h es desconocida. Al ser \vec{u} un vector unitario se tiene que $\|\vec{u}\|^2 = 1$, pero,

$$\|\vec{u}\|^2 = a^2 + b^2 + c^2 \quad (3.32)$$

De la Figura 3.12 se observa que:

$$\|\vec{u}\|^2 = a^2 + h^2 \quad (3.33)$$




Figura 3.12: Rotación de \vec{u} para hacerlo coincidir con el plano XZ.

De las ecuaciones 3.32 y 3.33 se concluye que:

$$h^2 = b^2 + c^2 \quad (3.34)$$

Sin embargo, en la ecuación 3.30 se define a $d^2 = b^2 + c^2$ entonces:

$$h = d \quad (3.35)$$

657 Con las ecuaciones anteriores se obtienen los elementos necesarios para construir
658 la matriz de giro alrededor del eje coordenado Y:

659 $\cos(-\alpha) = \frac{d}{1}$ pero $\cos(-\alpha) = \cos(\alpha)$.

660 $\sin(-\alpha) = -\sin(\alpha)$ entonces

661 $-\sin(\alpha) = -\frac{a}{1}$.

662 La matriz de giro G_y queda definida como:

$$G_y = \begin{pmatrix} d & 0 & -a & 0 \\ 0 & 1 & 0 & 0 \\ a & 0 & d & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.36)$$

Aplicar el giro deseado Una vez que el eje de giro \vec{u} se encuentra alineado con el eje coordenado Z , se debe aplicar el giro θ con respecto a dicho eje, siendo la matriz de giro G_z con respecto a Z la siguiente:

$$R_z = \begin{pmatrix} \cos(\theta) & \sin(\theta) & 0 & 0 \\ -\sin(\theta) & \cos(\theta) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.37)$$

Aplicar transformaciones inversas Es necesario aplicar las transformaciones inversas para devolver al eje de giro a su orientación original.

Con lo anterior, la ecuación para girar a un objeto alrededor de un eje arbitrario \vec{v} queda definida como:

$$G(\theta) = T^{-1}G_x^{-1}G_y^{-1}G_zG_xT \quad (3.38)$$

663 Donde $T^{-1}, G_x^{-1}, G_y^{-1}$ son las transformaciones inversas.

664 3.8. Dimensión fractal

665 En este trabajo se realizaron cálculos similares a los propuestos por (Kim et al.,
666 2014) referente a la dimensión fractal de la distribución de color, la cual permite
667 establecer qué tan homogénea o heterogénea es la distribución. Debido a lo anterior,
668 parece pertinente definir la dimensión fractal y, presentar el algoritmo utilizado para
669 calcularla.

670 Se dice que una línea es unidimensional, un cuadrado es bi-dimensional y que un
671 cubo posee tres dimensiones. La pregunta es, ¿por qué éstos objetos geométricos
672 poseen dichas dimensiones?

673 Los tres objetos mencionados poseen una característica importante en común: son
674 autosimilares. Por ejemplo, la línea puede ser dividida en 4 segmentos, cada uno de
675 la misma longitud; cada uno puede ser amplificado por un factor de 4 para producir
676 el segmento original. De la misma manera, se puede dividir al segmento en 7 partes
677 iguales, cada uno con un factor de amplificación de 7; también es posible dividirlo
678 en 20 partes con un factor de amplificación de 20. En general, una línea puede ser
679 dividida en \mathbf{N} segmentos similares con un factor de amplificación de \mathbf{N} .

680 El caso del cuadrado es distinto. Se puede dividir al cuadrado en cuatro cuadrados
681 autosimilares y el factor de amplificación para producir a la Figura original es de 2.
682 Si se divide en 9 cuadrados, el factor de amplificación es de 3. En el caso de dividirlo
683 en 25 cuadrados, el factor de amplificación es de 5. En resumen, el cuadrado puede
684 ser dividido en \mathbf{N}^2 elementos con un factor de amplificación de \mathbf{N} . Para finalizar, un
685 cubo puede ser dividido en \mathbf{N}^3 elementos autosimilares con un factor de amplificación
686 de \mathbf{N} .

687 La **dimensión** de un objeto se puede definir como el exponente del número de
688 elementos autosimilares con factor de amplificación \mathbf{N} en los cuales puede dividirse
689 dicho objeto (Devaney, 1995).

$$dimension = \frac{\log(\text{numero de elementos autosimilares})}{\log(\text{factor de amplificacion})} \quad (3.39)$$

690 Al aplicar la ecuación 3.39 a un cuadrado se tiene:

$$dimension = \frac{\log(N^2)}{N} = \frac{2 \log N}{N} = 2 \quad (3.40)$$


691 Estudiar la distribución de color en el espacio de color RGB permite determinar
 692 si dicha distribución es homogénea o heterogénea y fractal. Si la distribución es
 693 homogénea, la dimensión será igual a tres. En caso de que sea menor que tres,
 694 significa que la distribución de color en el espacio de color se concentra sobre algún eje
 695 específico o existe un color predominante. En otras palabras, al medir la dimensión
 696 fractal, se cuantifica la uniformidad espacial o fractalidad de los colores utilizados
 697 (Kim et al., 2014).

698 3.8.1. Algoritmo Box-counting

699 El algoritmo *box-counting* es un método que permite determinar si una estructura
 700 presenta o no propiedades de autosimilaridad. A continuación se describe de manera
 701 breve el proceso para llevar a cabo el método de *box-counting*. El proceso se muestra
 702 en dos dimensiones, sin embargo la transición a la versión de tres dimensiones es
 703 bastante directa.

- 704 1. Generar una caja que englobe a la Figura que se desea analizar.
- 705 2. Dividir la caja en n cajas iguales con longitud de lado r .
- 706 3. Contar las cajas no vacías. Es decir, aquellas que contienen, al menos, una
 707 parte de la Figura a analizar.
- 708 4. Duplicar el tamaño de las cajas, por lo tanto, la longitud del lado r de cada
 709 caja se reduce a la mitad.
- 710 5. Repetir el proceso con distinto número de cajas.
- 711 6. Graficar $\log(\frac{1}{r})$ vs $\log(ne)$ y ajustar una línea recta a la serie de puntos
 712 obtenidos.
 713 Donde ne es el número de cajas no vacías.
- 714 7. La pendiente de la recta ajustada será la dimensión fractal del objeto.

715 La Figura 3.13 muestra como se aplica el algoritmo de **box-counting**.



Nature Reviews | **Clinical Oncology**

Figura 3.13: Algoritmo de box-counting. Imagen tomada de (Lenon et al., 2015).

3.9. Voxelización

716

717 El mapa de color de la superficie asociada a la distribución de color será gene-
 718 rado con ayuda del proceso de voxelización. Para poder calcular la transformada
 719 de distancia de un objeto en 3D, es necesario recurrir a una versión voxelizada del
 720 mismo. A continuación, se define el proceso de voxelizado:

721 El proceso de voxelización consiste en convertir objetos geométricos desde su re-
 722 presentación geométrica continua a un conjunto de voxeles que mejor aproximen la
 723 forma del objeto continuo (Kaufman et al., 1993). La voxelización es un similar al
 724 proceso de rasterización (algoritmo de *scan-conversion*), el cual permite representar,
 725 un objeto continuo en 2 dimensiones, de manera discreta, a través de un conjunto
 726 de píxeles.

727 Dependiendo de las necesidades de cada aplicación, el objeto puede ser voxelizado
 728 solamente del contorno, resultando hueco al interior, o este puede presentarse tam-
 729 bién como un objeto completamente sólido. La Figura 3.14 muestra dos versiones de
 730 voxelizado para un mismo modelo. del lado derecho, se observa un modelo que fue

731 voxelizado únicamente del contorno, manteniendo el interior vacío. El modelo a la
732 derecha es sólido, es decir, el interior del modelo también fue llenado con voxeles.




Figura 3.14: Modelo voxelizado, interior vacío (izquierda). Modelo voxelizado, interior sólido (derecha). Imagen tomada de (Schwarz and Seidel, 2010).

733 3.10. Algoritmo Flood-fill

734 Con la ayuda de la versión 3D de este algoritmo, se rellenará el interior de la
735 versión voxelizada del elipsoide que mejor ajusta la distribución de color de una pin-
736 tura. Lo cual permitirá calcular la transformada de distancia con signo y, finalmente,
737 generar el mapa de color.

738 El propósito del algoritmo **Flood-fill** es rellenar o pintar de un mismo color un
739 área determinada por ciertos pixeles interconectados, dejando los bordes y los pixeles
740 fuera de dicha área intactos (Bhatia, 2008).

741 Este tipo de algoritmos se basan en métodos recursivos, inician con un pixel se-
742 milla al interior de la región a rellenar y pintan los pixeles vecinos, que no hayan
743 sido pintados, considerando una vecindad 8-conectados o 4-conectados (fig 3.15) ,
744 según las necesidades del problema. Los vecinos, a su vez, se convierten en nuevas
745 semillas, continuando así, el proceso recursivo hasta que la región haya sido comple-
746 tamente llenada o pintada. El algoritmo puede modificarse para crear una versión
747 que funcione en tres dimensiones, rellenando voxeles en lugar de pixeles.

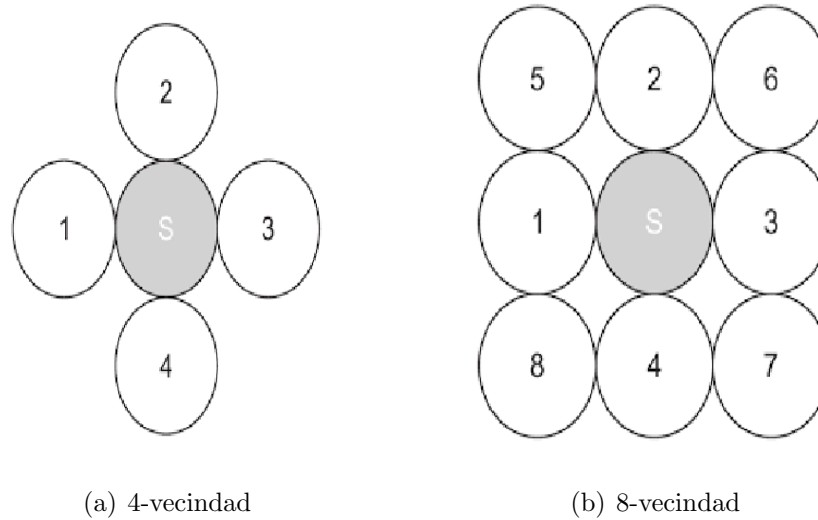


Figura 3.15: Tipos de vecindad que se pueden considerar en un pixel. Imágenes tomadas de (Bhatia, 2008).

748 **Pseudocódigo del algoritmo Flood-fill** Como ya se había mencionado, el al-
 749 goritmo *Flood-fill* se basa en la recursión. Es bastante fácil de implementar, sin
 750 embargo, debido a la naturaleza de la recursión puede causar un desbordamiento de
 751 memoria, en caso de que se requieran rellenar o pintar grandes áreas. En el algoritmo
 752 3.10.1 se puede observar lo simple que es este algoritmo.

753 La Figura 3.16 muestra el resultado de aplicar el algoritmo **Flood-fill** a cierta
 región.




Figura 3.16: Resultado de aplicar el algoritmo **Flood-fill** a una región.

Algorithm 3.10.1: Pseudocódigo del algoritmo Flood-fill recursivo

```
1 Function floodFill
   Input: Imagen a rellenar, semilla(x,y)
   Output: Imagen rellenada
2   pixel ← getPixel (imagen,semilla);
3   /* El pixel ya está pintado */
4   if pixel == 1 then
5     | return;
6   end
7   else
8     /* Genera nuevas semillas, en este caso se utiliza
       4-vecindad */
9     /* vecino oeste */
10    floodfill (imagen,semilla.x+1,semilla.y);
11    /* vecino este */
12    floodfill (imagen,semilla.x-1,semilla.y);
13    /* vecino norte */
14    floodfill (imagen,semilla.x,semilla.y+1);
15    /* vecino sur */
16    floodfill (imagen,semilla.x,semilla.y-1);
17  end
18 end
```


755 **Capítulo 4**

756 **Herramientas para el análisis de** 757 **texturas**

758 **4.1. Antecedentes**

759 De acuerdo a (Hajek et al., 2006) una textura se define como una serie de patrones
760 complejos, compuestos de entidades organizadas espacialmente, las cuales poseen
761 brillo, color, forma y tamaño característico. Por otro lado, (Jain and Schunk, 1995)
762 define a la textura como patrones repetitivos de variaciones locales en una imagen
763 de intensidades los cuales son demasiado finos para ser distinguidos como objetos
764 separados a la resolución observada. Cabe mencionar que existen texturas que no
765 presentan patrones regulares o repetitivos por lo que las definiciones mencionadas
766 anteriormente no logran englobar totalmente el universo de texturas existentes.

767 La textura de algunas imágenes se caracteriza parcialmente por la distribución
768 espacial de los niveles de gris en un vecindario (Jain and Schunk, 1995) (Taji and
769 Gore, 2013).

770

771 **4.1.1. Métodos de análisis de texturas**

772 Existen ciertos métodos con diversos enfoques que permiten extraer información
773 característica de la textura de una imagen, como son: estadísticos, estructurales,
774 basados en modelos, y de procesamiento de señales.

775 **Método estructural**

776 Representan a la textura como un conjunto de elementos texturales (texones). La
777 textura se define a través de microtextura y macrotextura, la cual, está compuesta
778 de un arreglo de micro-texturas. La ventaja de este enfoque es que provee buena
779 descripción simbólica de la imagen. Este método ha probado ser útil en medicina,
780 especialmente para la detección de cambios en la microestructura ósea (Taji and
781 Gore, 2013).

782 **Método estadístico**

783 La textura se representa indirectamente por propiedades no determinísticas que
 784 gobiernan las distribuciones y relaciones entre los niveles de gris de una imagen. La
 785 textura se describe como una colección de características estadísticas que pueden
 786 ser de primer orden, si se aplica sobre los valores de niveles de gris de un pixel, o
 787 de segundo orden, si se calcula la diferencia de iluminación entre dos pixeles a una
 788 distancia d . Los descriptores más comunes de segundo orden se obtienen a través de
 789 la matriz de co-ocurrencia (GLCM) (Taji and Gore, 2013).

790 **Método basado en modelos**

791 Este método trata de caracterizar la textura al determinar un modelo analítico
 792 de la imagen que se analiza. Dichos modelos tienen un conjunto de parámetros que
 793 determinan las propiedades de la textura, la cual, puede ser sintetizada al aplicar
 794 el modelo (Jain and Schunk, 1995). Por ejemplo, los campos aleatorios de Markov
 795 (MRF por sus siglas en inglés) han sido utilizados como modelos de textura.

796 **Métodos de transformadas**

797 Involucran técnicas como las transformadas de Fourier, Gabor y ondeleta. Estas
 798 técnicas representan una imagen en un espacio cuyo sistema de coordenadas tie-
 799 ne una interpretación relacionada cercanamente a las características de la textura,
 800 por ejemplo, la frecuencia. Los métodos basados en la transformada de Fourier se
 801 desempeñan pobremente debido a la falta de localización espacial. Los filtros de Ga-
 802 bor tienen utilidad limitada debido a que no existe una sola resolución de filtros a la
 803 cual se puedan encontrar estructuras espaciales en texturas naturales. Finalmente,
 804 la desventaja de utilizar ondeletas radica en que la transformada no es invariante a
 805 la traslación (Materka and Strzelecki, 1998).

806 **4.2. Matriz de co-ocurrencia de niveles de gris**

807 La matriz de co-ocurrencia de niveles de gris (GLCM por sus siglas en inglés)
 808 fue introducida por Robert Haralick.

809 La GLCM es una matriz de dos dimensiones, que se construye de acuerdo a la
 810 probabilidad conjunta de que ocurran los niveles de gris i y j , para dos pixeles con
 811 relación espacial definida en términos de una distancia d y un ángulo θ (Sharma and
 812 Singh, 2001).

Definición Sea $I(f, c)$ una imagen con f filas y c columnas, d un vector de despla-
 zamiento (d_f, d_c) donde d_f es el desplazamiento de las filas y d_c es el desplazamiento
 de las columnas. Sea L el conjunto de niveles de gris que componen a $I(f, c)$, la
 matriz de co-ocurrencia de niveles de gris $G(L_i, L_j)$, donde $G(L_i, L_j) = 0 \forall L_i, L_j$,
 para la imagen $I(f, c)$ se define como sigue:

$$G(L_i, L_j) = G(L_i, L_j) + 1 \text{ si } I(f, c) = L_i \text{ y } I(f + d_f, c + d_c) = L_j \quad (4.1)$$

813 La Figura 4.1 ilustra el cálculo de tres matrices de co-ocurrencia utilizando tres
 814 vectores de desplazamiento distintos para una imagen de 4x4 con tres niveles de
 815 gris.




Figura 4.1: Tres matrices de co-ocurrencia para una imagen en niveles de gris. Imagen tomada de (Shapiro and Stockman, 2001).

816 **4.2.1. GLCM normalizada**

La matriz de co-ocurrencia normalizada, contiene valores que se encuentran solamente entre cero y uno. Lo anterior, permite visualizar a la matriz como una matriz de probabilidades (Shapiro and Stockman, 2001). La GLCM normalizada se define como sigue:

$$G_n(L_i, L_j) = \frac{G(L_i, L_j)}{\sum_{L_i} \sum_{L_j} G(L_i, L_j)} \tag{4.2}$$

817 **4.2.2. GLCM simétrica**

Como su nombre sugiere, la matriz de co-ocurrencia de niveles de gris es simétrica respecto a la diagonal principal. Esta se define a continuación:

$$G_s(L_i, L_j) = G(L_i, L_j) + G(L_j, L_i) \tag{4.3}$$

818 donde $G(L_i, L_j)$ se calcula con el vector de desplazamiento $d(d_f, d_c)$ y $G(L_j, L_i)$ se
 819 calcula con el vector de desplazamiento $-d(d_f, d_r)$.

820 El algoritmo 4.2.1 muestra de manera detallada cómo generar la matriz de co-
 821 ocurrencia normalizada y simétrica, posterior a la cuantización de imagen.

822 **4.2.3. Descriptores estadísticos obtenidos a partir de la GLCM**

823 Para lograr estimar la similitud entre distintas matrices de co-ocurrencia, Hara-
 824 lick propuso 14 descriptores estadísticos que podrían ser extraídos de las matrices.

Algorithm 4.2.1: Algoritmo para calcular la matriz de co-ocurrencia de niveles de gris.

```

1 Function CalculaGLCM
   Input: Imagen cuantizada, vector dirección
   Output: GLCM
2   total  $\leftarrow$  0;
3   for filas in imagen do
4     for columnas in imagen do
5       /* Valida que no se excedan las dimensiones de la
6         imagen */
7       if filas +vectorDir.filas  $\geq$  imagen.filas || columnas
8         +vectorDir.columnas  $\geq$  imagen.columnas then
9         end
10        /* Proceda a la siguiente iteración */
11        continue;
12        /* obtiene el valor del pixel de referencia o pivote y
13          el valor del pixel dado por el vector dirección */
14        referencia  $\leftarrow$  imagen (filas,columnas);
15        vecino  $\leftarrow$  imagen (filas +vectorDir.filas,columnas
16          +vectorDir.columnas);
17        /* Al ser iguales, cuenta una sola vez */
18        if referencia ==vecino then
19          GLCM (referencia,vecino)+=1;
20          total +=1;
21        end
22        /* Para volver simétrica a la matriz cuenta doble y en
23          posiciones invertidas */
24        else
25          GLCM (referencia,vecino)+=1;
26          GLCM (vecino,referencia)+=1;
27          total +=2;
28        end
29        /* Normaliza la GLCM para que tenga valores entre 0 y 1
30          */
31        GLCM / =total;
32      end
33    end
34  end

```

825 Dichos descriptores se obtienen a partir de una GLCM normalizada y simétrica.
 826 Para los siguientes descriptores, se considera a $p(i, j)$ el valor en el (i, j) -ésimo ele-
 827 mento de la matriz de co-currencia de niveles de gris.

828 **Contraste**

Es una medida de la intensidad o de las variaciones de niveles de gris que ocurren entre el pixel de referencia y su vecino (Zayed and Elnerm, 2015).

$$Contraste = \sum_i \sum_j (i - j)^2 p(i, j) \quad (4.4)$$

829 **Homogeneidad (Inverse Difference Moment)**

Mide qué tan cercanos son los elementos de la GLCM a su diagonal (Zayed and Elnerm, 2015). Muestra valores altos para imágenes homogéneas y valores pequeños para imágenes no homogéneas.

$$\sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j) \quad (4.5)$$

830 **Entropía**

Es el grado de desorden o aleatoriedad presente en una imagen. Este valor es el mayor cuando todos los elementos de la matriz son iguales y pequeño cuando todos los elementos son distintos (Zayed and Elnerm, 2015).

$$Entropia = - \sum_i \sum_j p(i, j) \ln(p(i, j)) \quad (4.6)$$

831 **Segundo Momento Angular**

Mide la uniformidad local de los niveles de gris. Cuando los pixeles son muy similares, el valor obtenido sera grande (Zayed and Elnerm, 2015).

$$ASM = \sum_i \sum_j (p(i, j))^2 \quad (4.7)$$

832 **Correlación**

Muestra la dependencia lineal de los niveles de gris en la matriz de co-ocurrencia.

$$Correlacion = \sum_i \sum_j p(i, j) \frac{(i - \mu_x)(j - \mu_y)}{\sigma_x \sigma_y} \quad (4.8)$$

833 Donde $\mu_x = \sum_i \sum_j i p(i, j)$

834

835 $\mu_y = \sum_i \sum_j j p(i, j)$

836

837 $\sigma_x = \sqrt{\sum_i \sum_j (i - \mu_x)^2 p(i, j)}$

838
839 $\sigma_y = \sqrt{\sum_i \sum_j (i - \mu_y)^2 p(i, j)}$

840 **Disimilitud**

$$\sum_i \sum_j p(i, j) |i - j| \tag{4.9}$$

841 **4.3. Patrones binarios locales**

842 Patrones locales binarios (LBP por sus siglas en inglés) son un método robusto
843 para describir la textura de una imagen (Khorsheed and Yurtkan, 2016).
844 Este operador utiliza los ocho vecinos que rodean a un pixel y compara el valor
845 de intensidad de cada pixel vecino con el pixel central. Asigna el valor de cero al
846 vecino si el valor de intensidad que posee es menor que el valor del pixel central, en
847 caso contrario, asigna el valor uno. Finalmente, se genera una etiqueta para el pixel
848 central al interpretar los valores asignados a los vecinos como un número binario de
849 8 bits, para posteriormente, convertirlo a su equivalente decimal.

850
851 La Figura 4.2 muestra una imagen de 3x3 conformada por un pixel central y sus
852 ocho vecinos. Muestra también, los valores asignados a cada vecino tras comparar los
853 valores de intensidad de cada uno con el del pixel central. Por último, se interpreta
854 a la combinación de valores asignados a los vecinos como un número binario, y se
obtiene la etiqueta decimal que se asignará al pixel central.




Figura 4.2: Cálculo de la etiqueta para un pixel central, tomando en cuenta a sus ocho vecinos. Imagen tomada de (Wagner, n.d.).

855 De manera formal, dado un pixel central $pix(x_c, y_c)$, el valor de LBP que se asigna a dicho pixel expresado en forma decimal se define como sigue (Huang et al., 2011):

$$LBP(x_c, y_c) = \sum_{p=0}^{p-1} s(i_p - i_c) 2^p \tag{4.10}$$

Donde: i_c e i_p son los valores de intensidad de gris del pixel central y de los pixeles vecinos respectivamente. $s(x)$ se define como:

$$s(x) = \begin{cases} 1 & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases} \tag{4.11}$$

856 4.3.1. Patrones binarios locales uniformes

857 Los patrones binarios locales uniformes o **ULBP** (*Uniform Local Binary Pat-*
 858 *terns*) son una variante de los LBP, solo que en el caso de ULBP, se consideran
 859 como patrones uniformes a aquellos que tienen como máximo dos transiciones de
 860 0-1 ó 1-0 (Lahdenoja et al., 2013). Por ejemplo, los patrones 00111000, 11111111, y
 861 11011111 son uniformes. Por otro lado, 01010000, 01001110 ó 10101100 se consideran
 862 como patrones no uniformes.

Durante el cálculo del histograma, se genera un bin¹ para cada patrón uniforme, mientras que los patrones no uniformes se consideran en un solo bin. El número de bins o etiquetas requeridos para el histograma ULBP está dado por la siguiente fórmula:

$$bins = p(p - 1) + 3 \quad (4.12)$$




Figura 4.3: Patrones uniformes considerados para ULBP considerando 8 píxeles vecinos. Imagen tomada de (Pietikäinen et al., 2011).

863 Donde, p es le número de vecinos considerados.

864

865 En la Figura 4.3 cada par $U_p(n, r)$ denota un patrón uniforme, donde n es el
 866 número de bits con valor igual a uno en el patrón (filas de la Figura 4.3), y r es

¹Categoría o clase donde se agrupan patrones con características similares.

867 la rotación del patrón (columnas en la Figura 4.3). Si el vecindario tiene P puntos
868 de muestreo, n varía de 0 a $P + 1$, cuando $n = p + 1$ se considera el bin o etiqueta
869 especial para todos los patrones no uniformes.

870 Para obtener los patrones uniformes se sigue un procedimiento similar al mostra-
871 do en LBP. La diferencia radica en que al calcular el patrón se determina si es o no
872 uniforme. En caso de que sea un patrón uniforme, se asigna a un bin característico,
873 en caso contrario, todos los patrones no uniformes se asignan a un solo bin.

874 Las razones para no utilizar los patrones no uniformes son las siguientes: Primero,
875 la mayoría de los LBP en imágenes naturales son uniformes, teniendo una presencia
876 de hasta el 90 % respecto a todos los patrones encontrados en una imagen. Segundo,
877 se ha demostrado que los patrones uniformes son más estables, es decir, son menos
878 sensibles a ruido (Pietikäinen et al., 2011).

879 4.3.2. Patrones binarios locales dominantes

880 En (Liao et al., 2009) se presenta el concepto de patrones binarios locales domi-
881 nantes o **DLBP** (*dominant local binary patterns*). De acuerdo a (Liao et al., 2009),
882 la técnica de *dominant local binary patterns* considera los patrones que ocurren con
883 mayor frecuencia al analizar la textura de una imagen. Asimismo (Liao et al., 2009)
884 considera a los **DLBP** como aquellos que representan alrededor del 80 % del total
885 de ocurrencias de los patrones encontrados en una imagen. A diferencia del enfoque
886 tradicional con LBP o ULBP, al usar **DLBP**, el número de patrones no está limi-
887 tado a un número fijo ya que para dos imágenes distintas, los patrones dominantes
888 pueden ser también distintos (Liao et al., 2009).

889 Para obtener el histograma de *dominant local binary patterns*, se calcula de ma-
890 nera tradicional el histograma de **LBP**. Posteriormente, este histograma se ordena
891 de forma decreciente, hasta alcanzar el 80 por ciento de ocurrencias del total de
892 ocurrencias de los patrones.

893 Capítulo 5

894 Metodología

895 5.1. Normalización de medias y desviación estándar

Con el propósito de disminuir las variación provocadas durante la adquisición y digitalización de las pinturas, se pretende ajustar los valores de media y desviación estándar de cada pintura al valor promedio de dichos parámetros de las pinturas analizadas. Dado un conjunto Ω de pinturas, se pretende ajustar la media y desviación estándar de cada pintura P_i a la media y desviación estándar promedio de Ω . Sean \bar{X}_Ω y σ_Ω la media y desviación estándar promedio de Ω respectivamente, se definen de la siguiente forma:

$$\bar{X}_\Omega = \sum_{i=1}^N \frac{\bar{X}_i}{N} \quad (5.1)$$

896 Donde $N = \text{card}(\Omega)$ y \bar{X}_i es la media de cada pintura $p_i \in \Omega$

$$\sigma_\Omega = \sum_{i=1}^N \frac{\sigma_i}{N} \quad (5.2)$$

897 Donde $N = \text{card}(\Omega)$ y σ_i es la media de cada pintura $p_i \in \Omega$

898 5.1.1. Pseudocódigo para ajustar la media y desviación estándar 899 de un conjunto de Imágenes

Algorithm 5.1.1: Algoritmo para calcular la media y desviación estándar promedio de las pinturas estudiadas.

```

1 Function calc_adjusted_DevMean
   Input: Imagenes a analizar
   Output: Desviación estándar promedio, media promedio para cada canal
             R,G,B
2 for  $i \leftarrow 1$  to NUM_IMAGENES do
3     /* separa la imagen en los canales R,G B */
4     RGB_channels  $\leftarrow$  Split(imageni);
5     /* Acumula la media de cada canal */
6     meanR  $\leftarrow$  Mean(RGB_channels.red)+meanR;
7     meanG  $\leftarrow$  Mean(RGB_channels.green)+meanG;
8     meanB  $\leftarrow$  Mean(RGB_channels.blue)+meanB;
9     /* Acumula la desviación estándar de cada canal */
10    devR  $\leftarrow$  std (RGB_channels.red)+devR;
11    devR  $\leftarrow$  std (RGB_channels.green)+devG;
12    devR  $\leftarrow$  std (RGB_channels.blue)+devB;
13 end
14 /* Calcula los promedios */
15 meanR  $\leftarrow$  meanR/NUM_IMAGENES;
16 meanG  $\leftarrow$  meanG/NUM_IMAGENES;
17 meanB  $\leftarrow$  meanB/NUM_IMAGENES;
18 devR  $\leftarrow$  devR/NUM_IMAGENES;
19 devG  $\leftarrow$  devG/NUM_IMAGENES;
20 devB  $\leftarrow$  devB/NUM_IMAGENES;
21 end

```

Algorithm 5.1.2: Algoritmo para ajustar las media y desviación estándar de cada canal de las pinturas estudiadas.

```

1 Function Normalize_images
   Input: Imagenes a normalizar, media y desviación estándar promedio por
           cada canal de color
   Output: Imagenes normalizadas
2 for  $i \leftarrow 1$  to NUM_IMAGENES do
3     /* Separa la imagen en los 3 canales de color R,G,B      */
4     RGBChannels  $\leftarrow$  split (Imageni);
5     /* Calcula las constantes por las cuales se debe
           multiplicar cada canal para obtener la desviación
           estándar deseada, de acuerdo a lo visto en B.18      */
6      $K_r \leftarrow$  avStd.red/std (RGBChannels.red);
7      $K_g \leftarrow$  avStd.green/std (RGBChannels.green);
8      $K_b \leftarrow$  avStd.blue/std (RGBChannels.blue);
9     normalized_r  $\leftarrow$  RGBChannels.red* $K_r$ ;
10    normalized_g  $\leftarrow$  RGBChannels.green* $K_g$ ;
11    normalized_b  $\leftarrow$  RGBChannels.blue* $K_b$ ;
12    /* Ajusta las medias de cada canal                        */
13    /* Sustraer la media del canal ajustado y agrega la media
           deseada                                             */
14    normalized_r  $\leftarrow$  normalized_r-mean (nR)+avMeans.red;
15    normalized_g  $\leftarrow$  normalized_g-mean (nG)+avMeans.green;
16    normalized_b  $\leftarrow$  normalized_b-mean (nB)+avMeans.blue;
17    /* Combina nuevamente, los tres canales normalizados    */
18    normalized_image  $\leftarrow$  merge (normalized_r, normalized_g,normalized_b);
19 end
20 end

```



Figura 5.1: Ejemplo de pinturas antes de ajustar sus valores de media y desviación estándar.




Figura 5.2: Pinturas después de ajustar media y desviación estándar.

900 5.2. Generación del elipsoide que mejor ajusta la 901 distribución de color

902 5.2.1. Visualización de la distribución de color

903 El algoritmo para calcular el histograma de color de una pintura se presenta a
904 continuación.

Algorithm 5.2.1: Algoritmo para generar el histograma de una imagen a color.

```

1 Function GeneraHistograma3D
  Input: Imagen
  Output: Histograma de la imagen
2 foreach pixel  $\in$  Imagen do
3   pixel = readPixel (Imagen);
4   Histograma[pixel.red][pixel.green][pixel.blue] +=1;
5 end
6 end

```

905 5.2.2. Cálculo y visualización de ejes principales

906 En lugar de utilizar la matriz de co-ocurrencia, como normalmente se hace al
907 realizar análisis de componentes principales sobre un conjunto de datos, en esta
908 ocasión se decidió utilizar el centro de masa de la distribución de color y el tensor
909 de inercia asociado a la misma. Lo anterior tiene como objetivo otorgar mayor peso
910 a los pixeles que aparecen con mayor frecuencia en la pintura.

911 Centro de Masa y tensor de inercia

En el capítulo 3 (ecuaciones 3.13 y 3.14) se discutió el cálculo del tensor de inercia y el centro de masa de la distribución de color de una pintura. Con ayuda de **openCV** se extraen del tensor de inercia los valores y vectores propios asociados (*eigenvalores* y *eigenvectores*). Los valores propios del tensor de inercia se expresan a través de una matriz de la siguiente manera:

$$\begin{pmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{pmatrix} \quad (5.3)$$

912 Donde $\lambda_1 > \lambda_2 > \lambda_3$

913 5.2.3. Factores de escala para el elipsoide

914 Los semiejes del elipsoide de inercia que ajusta a la distribución de color se
915 definen a continuación:

916 $a = \frac{2}{\sqrt{\lambda_1}}, \quad b = \frac{2}{\sqrt{\lambda_2}}, \quad c = \frac{2}{\sqrt{\lambda_3}}$


Dado que el elipsoide rara vez ajusta al objeto original o volumen de interés, este requiere ser escalado de alguna manera. Un criterio de ajuste es que el volumen del elipsoide concuerda con el volumen del objeto original, obteniendo así:

$$escala = \left(\frac{3Volumen(O)}{4\pi abc} \right)^{\frac{1}{3}} \quad (5.4)$$


917 Donde O es el objeto original.

918 5.2.4. Visualización del elipsoide que mejor ajusta y ejes 919 principales

920 Tras calcular el centroide y los ejes principales de la distribución de color de una
921 pintura, se procede a visualizarlos. En la Figura 5.3 se muestran los ejes principales
922 y el elipsoide que mejor ajusta a la distribución de color. Cabe mencionar, que el
923 origen del sistema de ejes principales se encuentra en el punto definido por el centro
924 de la distribución.



(a) *Gala contemplando el Mediterráneo*.
(1976)



(b) Distribución de color, ejes principales y elipsoide que mejor ajusta

Figura 5.3: *Gala contemplando el Mediterráneo* y distribución de color con ejes principales y elipsoide que mejor ajusta.

925 Alineación del elipsoide con los ejes principales

926 Debido a que se desconocen inicialmente las rotaciones necesarias para ir del
927 sistema XYZ al sistema definido por los ejes principales de la distribución de color
928 de la pintura, se cuenta de inicio, con un elipsoide centrado en el origen y orientado
929 respecto a alguno de los ejes coordenados. La Figura 5.4 muestra al elipsoide asociado
930 a la distribución de color sin estar alineado con los ejes principales.

931 Para obtener los ángulos de rotación necesarios para alinear el elipsoide correc-
932 tamente, se realiza un procedimiento similar al visto en el capítulo 3, en el apartado
933 de **Rotación respecto a un eje arbitrario** 3.7.3. En la Figura 5.4 se observa que

5.2. GENERACIÓN DEL ELIPSOIDE QUE MEJOR AJUSTA LA DISTRIBUCIÓN DE COLOR

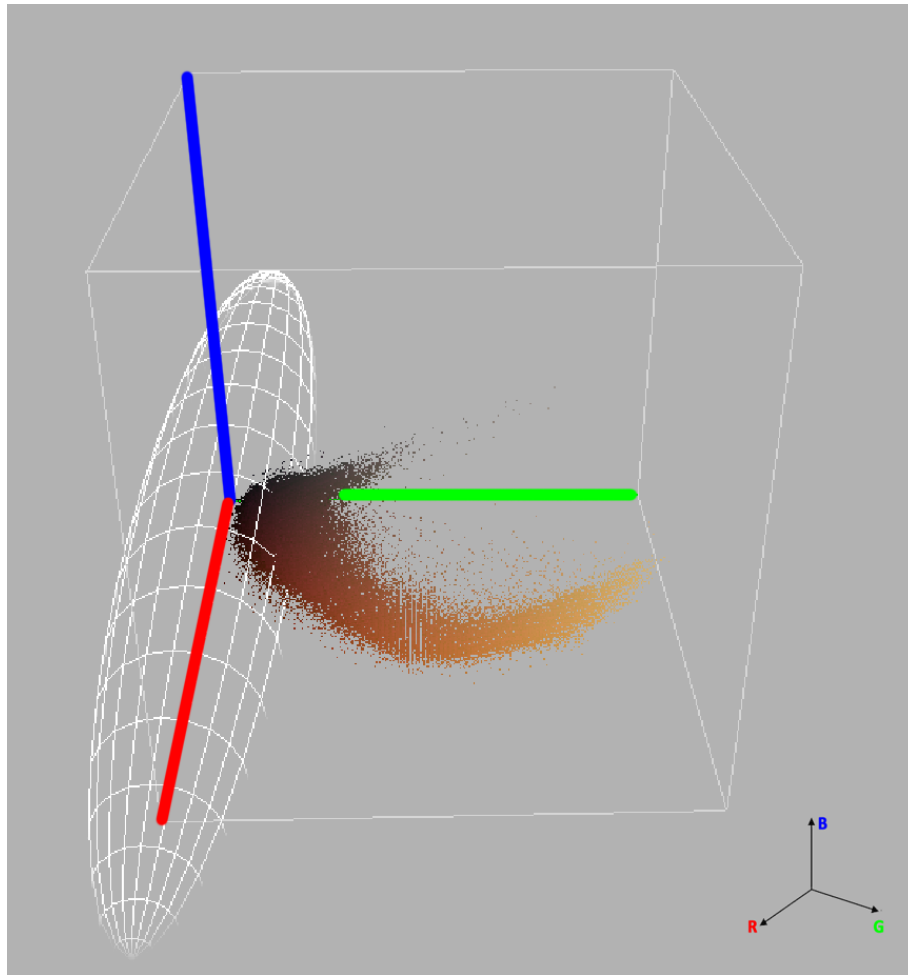


Figura 5.4: Elipsoide centrado en el origen.

934 el semieje mayor del elipsoide está alineado con el eje coordenado Z. Por esta razón,
935 el *eigenvector* mayor del sistema de ejes principales será alineado con el eje coor-
936 denado Z para el cálculo de las rotaciones. El procedimiento utilizado se describe a
937 continuación:

938 **Traslación del origen del sistema formado por los ejes principales al origen**
939 **del sistema XYZ** Se aplica una traslación $t = (-x_c, -y_c, -z_c)$, donde x_c, y_c, z_c
940 son las coordenadas del origen del sistema formado por los vectores propios asociados
941 a la distribución de color.

Cálculo de la rotación respecto al eje coordenado X Se toma al *eigenvector*
de mayor longitud y se hace coincidir con el plano XZ, a través de una rotación
respecto al eje coordenado X, de la misma forma que en **Rotación respecto a un**
eje arbitrario 3.7.3. De la ecuación 3.31, se sabe que la matriz para alinear un

vector unitario con dirección cualquiera al plano XZ es la siguiente:

$$G_x = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & \frac{c}{d} & \frac{b}{d} & 0 \\ 0 & -\frac{b}{d} & \frac{c}{d} & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (5.5)$$

942 Donde b y c son la segunda y tercera componentes del vector unitario y $d =$
 943 $\sqrt{b^2 + c^2}$. Se tiene entonces que $\cos(\varphi) = \frac{c}{d}$, por lo tanto, el ángulo de rotación
 944 respecto a X se define como:

$$rot_x = \arccos\left(\frac{c}{d}\right) \quad (5.6)$$

Alineación con el eje coordenado Z El *eigenvector* que ahora yace en el plano XZ, debe ser alineado con el eje coordenado Z. Para esto, es necesario aplicar un giro con respecto al eje coordenado Y. Dicha matriz se definió en 3.36 y luce como sigue:

$$G_y = \begin{pmatrix} d & 0 & -a & 0 \\ 0 & 1 & 0 & 0 \\ a & 0 & d & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Donde a es el primer componente del vector que se va a alinear. En el caso de esta matriz se tiene que $\cos(\alpha) = \frac{d}{\sqrt{a^2 + d^2}}$, entonces el ángulo de rotación rot_y necesario para alinear el vector contenido en el plano XZ esta definido como:

$$rot_y = \arccos\left(\frac{d}{\sqrt{a^2 + d^2}}\right) \quad (5.7)$$

Después de realizar las transformaciones anteriores se obtiene al *eigenvector* con mayor valor perfectamente alineado con el eje coordenado Z, sin embargo, los dos ejes restantes aún no coinciden con el sistema coordenado XYZ. Se observó que el segundo eje principal se quedó contenido en el plano XZ. Es necesaria una rotación más con respecto al eje Z para que los ejes restantes queden alineados. El ángulo de rotación rot_z se calcula como sigue: Sea $pa2$ el vector unitario que contiene la dirección del segundo eje principal asociado a la distribución de color y sea, $rotPA2$ el mismo vector unitario tras aplicarle las rotaciones rot_x y rot_y , es decir,

$$rotPA2 = rot_y rot_x pa2 \quad (5.8)$$

Para calcular el ángulo θ que existe entre el segundo eje principal y el eje coordenado Y se obtienen las componentes del segundo eje principal sobre el eje X y el eje Y. Se tiene entonces que:

$\tan(rot_z) = \tan\left(\frac{\text{componenteY}}{\text{componenteX}}\right)$ por lo tanto:

$$rot_z = \arctan\left(\frac{\text{componenteY}}{\text{componenteX}}\right) \quad (5.9)$$

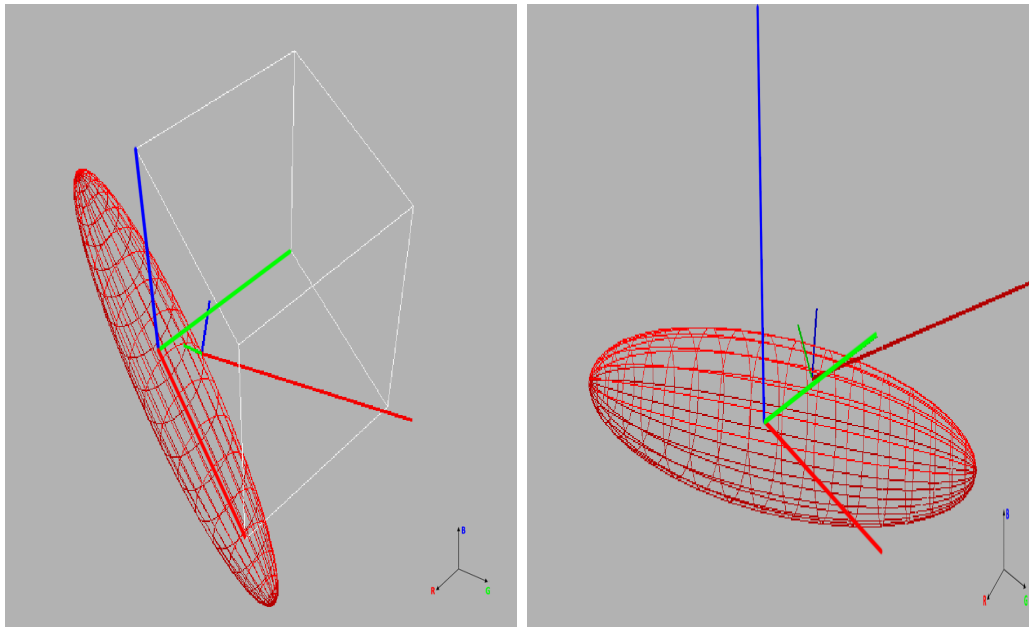
945 Tras la última rotación rot_z el sistema de ejes principales queda alineado al sistema
 946 coordenado XYZ.

5.2. GENERACIÓN DEL ELIPSOIDE QUE MEJOR AJUSTA LA DISTRIBUCIÓN DE COLORES

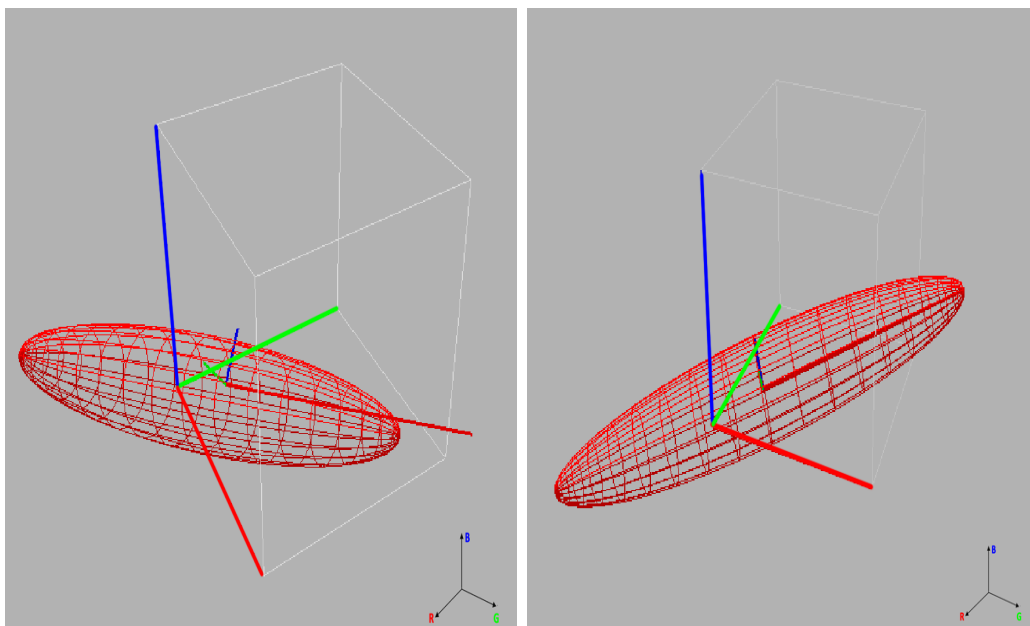
Aplicar rotaciones al elipsoide Finalmente, para obtener el elipsoide como se desea, se aplican las rotaciones en sentido inverso y ángulos invertidos, resultando de la siguiente manera:

$$elipsoideRotado = (traslacion)^{-1}(-rot_x)(-rot_y)(-rot_z)elipsoideOriginal \quad (5.10)$$

947 La Figura 5.5 muestra las rotaciones aplicadas al elipsoide sobre cada eje coor-
948 denado para alinearlo con los ejes principales obtenidos a partir de la distribución de
949 color. Se muestra también la traslación efectuada para llevar al elipsoide desde el
950 origen del sistema XYZ al origen del sistema de ejes principales. Se omitió a propósi-
951 to la visualización de la distribución de color, para observar con mayor facilidad el
952 proceso seguido para alinear el elipsoide con el sistema de ejes principales.



(a) Elipsoide en origen del sistema XYZ tras aplicarle la rotación $rotZ$ alrededor del eje Z. (b) Elipsoide en el origen del sistema XYZ tras aplicarle la rotación $rotY$ alrededor del eje Y.



(c) Elipsoide en el origen del sistema XYZ tras aplicarle la rotación $RotX$ alrededor del eje X. (d) Traslación del elipsoide desde el origen del sistema XYZ al origen del sistema de ejes principales.

Figura 5.5: Inicialmente se muestra al elipsoide ubicado en el origen del sistema XYZ y se muestra también, al sistema de ejes principales de la distribución de color. A lo largo de las subFiguras se muestra el proceso que se sigue para alinear el elipsoide con el sistema de ejes principales de la distribución de color. Las subFiguras a), b) y c) muestran el orden de las rotaciones aplicadas. La subFigura d) muestra la translación desde el origen del sistema XYZ al origen del sistema de ejes principales.

953 5.3. Mapa de color de la superficie generada a 954 partir de la distribución de color

955 Para generar el mapa de color de la superficie asociada a la distribución de color,
956 se requiere conocer la posición de cada vértice de la superficie respecto al elipsoide
957 ajustado. Si el vértice se encuentra fuera del elipsoide, este será pintado color azul.
958 Al contrario, si el vértice se encuentra dentro del elipsoide, el color adquirido será
959 rojo. Los puntos sobre la superficie, serán pintados de color blanco.
960 Ya sea que el vértice esté dentro o fuera del elipsoide, mientras más alejado de la
961 superficie se encuentre, el color asignado será más intenso. Por otro lado, mientras
962 más cercano se encuentre al contorno, el color asignado será degradado gradual-
963 mente hacia el color blanco. El proceso para generar el mapa de color se describe a
964 continuación:

- 965 1. **Voxelizar el elipsoide:** almacenar la información del voxelizado en una ma-
966 triz. Calcular el complemento de dicha matriz. Como se mencionó en el capítulo
967 3, voxelizar el elipsoide que mejor ajusta permite calcular el campo de distan-
968 cia, el cual permitirá asignar el color a la superficie generada a partir de la
969 distribución de color.
- 970 2. Calcular el **campo de distancia con signo** a partir de la matriz de voxelizado
971 y la matriz de voxelizado complemento.
- 972 3. Con la información contenida en el campo de distancia con signo, **asignar**
973 **color rojo** a los vértices de la superficie que se encuentren dentro del elipsoide.
974 Mientras más se alejen de la superficie y se acerquen al centro del elipsoide, el
975 color deberá ser más intenso. Los elementos que se encuentren en la superficie
976 serán color blanco. Pintar de color azul los elementos que se encuentren fuera
977 del elipsoide, mientras mas alejados de la superficie, el color deberá ser más
978 intenso.
- 979 4. **Visualizar** la superficie con el mapa de color correspondiente.

980 5.3.1. Voxelizado del elipsoide

981 El pseudocódigo del algoritmo empleado para voxelizar al elipsoide se muestra a
982 continuación:

983 En el algoritmo 5.3.1 se genera una caja englobante por cada triángulo pertene-
984 ciente al elipsoide. Posteriormente, se detectan a aquellos voxeles que coinciden, al
985 menos, parcialmente con la caja englobante del triángulo. Dichos voxeles se consi-
986 deran como parte del elipsoide.

987 La Figura 5.6 muestra el resultado de *voxelizar* el elipsoide a diferentes resolu-
988 ciones.

989

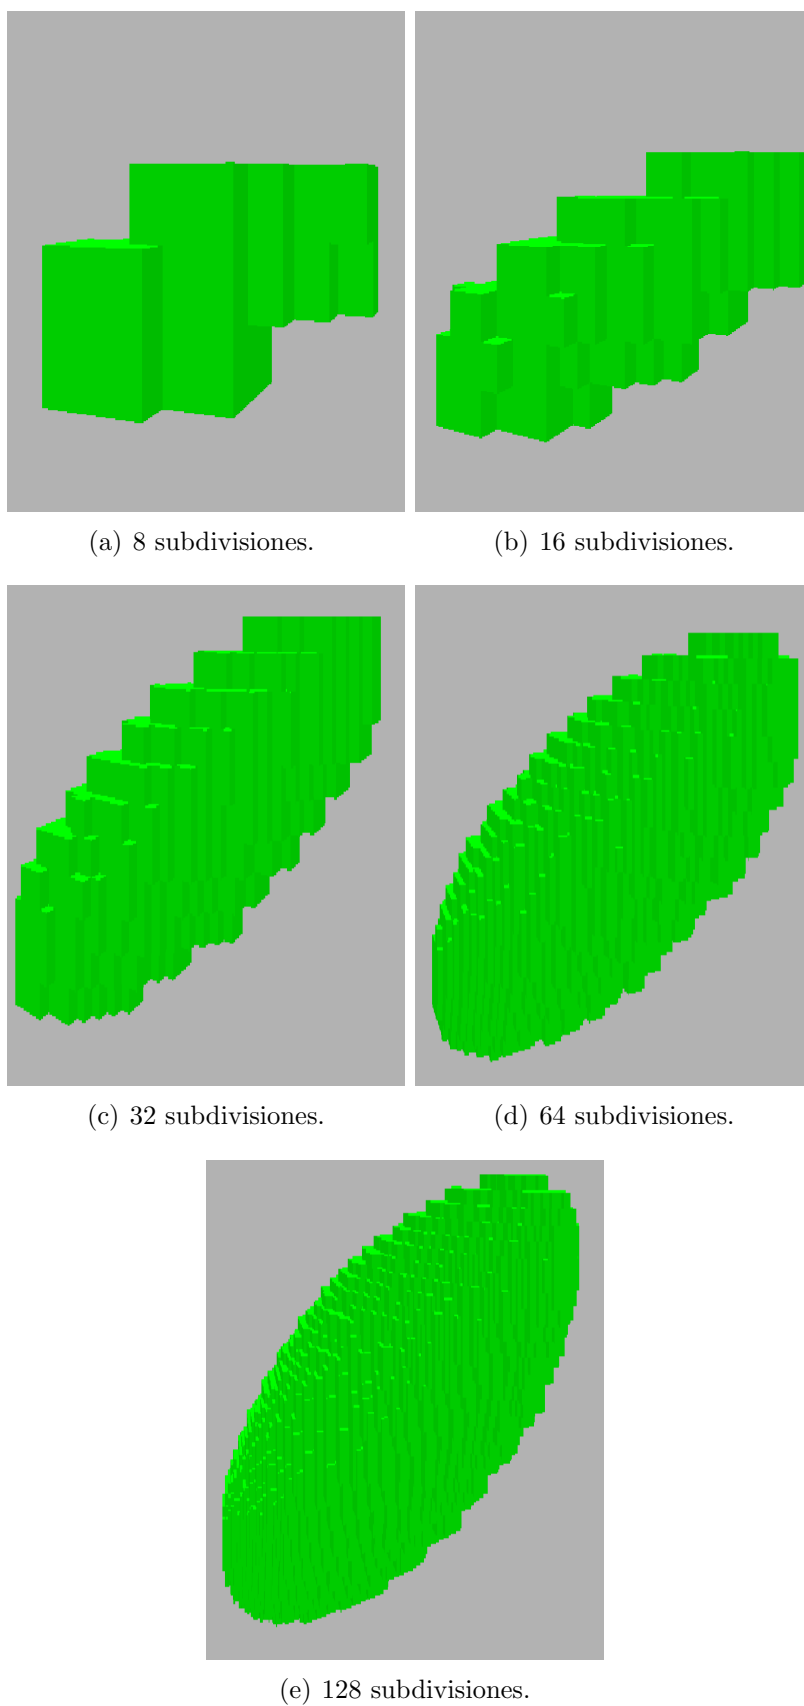


Figura 5.6: a) Elipsoide voxelizado utilizando 8 subdivisiones. b) Elipsoide voxelizado utilizando 16 subdivisiones. c) Elipsoide voxelizado utilizando 32 subdivisiones. d) Elipsoide voxelizado utilizando 64 subdivisiones. e) Elipsoide voxelizado utilizando 128 subdivisiones.

Algorithm 5.3.1: Algoritmo para voxelizar una malla de triángulos

```

1 Function voxelizado
   Input: Matriz para representar al objeto voxelizado inicializada en ceros,
           malla de triángulos del modelo a voxelizar
   Output: Matriz que representa al objeto voxelizado
2 foreach triangle in list-of-triangles do
3     /* Calcula la caja englobante para cada triángulo que
           compone la malla */
4     triangleBoundingBox ← calcTriangleBoundingBox (triangle);
5     /* Calcula los voxeles con los cuales se traslapa la caja
           englobante de cada triángulo */
6     VoxelsToPaint ← calcIntersectedVoxels (triangleBoundingBox);
7     /* pinta los voxeles con los que se traslapa la caja
           englobante de cada triángulo */
8     paintVoxels (VoxelsToPaint);
9 end
10 end

```

990 **Algoritmo para rellenar el interior del elipsoide voxelizado**

991 Para rellenar el interior del elipsoide voxelizado se utilizará una versión en tres
992 dimensiones del algoritmo 3.10.1. Para evitar problemas asociados a la recursión, el
993 algoritmo 5.3.3 utiliza una pila independiente para simular la recursión.

994 **5.3.2. Campo de distancia**

El campo de distancia con signo *signedEdt* se calcula de la siguiente manera:
Sea MV la matriz que contiene la información sobre los voxeles del elipsoide, y sea,
 MV^c la matriz complemento de MV . El campo de distancia *signedEdt*, está dado
por:

$$signedEdt = bwdist(MV) - bwdist(MV^c)^1 \quad (5.11)$$

995 **5.3.3. Cálculo del mapa de color**

996 Antes de calcular el mapa de color, es necesario generar la superficie que será
997 pintada, a partir de los puntos que conforman la distribución de color de la pintura.
998 Con ayuda del software **Amira**, se genera la superficie como se observa en la Figura
999 5.7. Posteriormente, dicha superficie se exporta y es cargada al programa principal.

¹Función de MatLab que permite calcular el campo de distancia.

Algorithm 5.3.3: Algoritmo flood fill 3D que utiliza una pila para simular la recursión

```

1 Function floodFill
   Input: Matriz de voxeles a rellenar, semilla(x,y,z)
   Output: Matriz rellena
2   matrizVoxeles (semilla.x,semilla.y,semilla.z)=1;
3   pila.push(semilla);
4   while !pila.vacia do
5     semilla ←pila.pop();
6     /* Utilizando 6-vecindad, revisa a los 6 vecinos que no
7        están pintados */
8     /* vecino izquierda */
9     if matrizVoxeles (semilla.x-1,semilla.y,semilla.z)==0 then
10    |   matrizVoxeles (semilla.x-1,semilla.y,semilla.z)←1;
11    |   pila.push(semilla (x-1,y,z));
12    end
13    /* vecino derecha */
14    if matrizVoxeles (semilla.x+1,semilla.y,semilla.z)==0 then
15    |   matrizVoxeles (semilla.x+1,semilla.y,semilla.z)←1;
16    |   pila.push(semilla (x+1,y,z));
17    end
18    /* vecino arriba */
19    if matrizVoxeles (semilla.x,semilla.y+1,semilla.z)==0 then
20    |   matrizVoxeles (semilla.x,semilla.y+1,semilla.z)←1;
21    |   pila.push(semilla (x,y+1,z));
22    end
23    /* vecino abajo */
24    if matrizVoxeles (semilla.x,semilla.y-1,semilla.z)==0 then
25    |   matrizVoxeles (semilla.x,semilla.y-1,semilla.z)←1;
26    |   pila.push(semilla (x,y-1,z));
27    end
28    /* vecino frente */
29    if matrizVoxeles (semilla.x,semilla.y,semilla.z+1)==0 then
30    |   matrizVoxeles (semilla.x,semilla.y,semilla.z+1)←1;
31    |   pila.push(semilla (x,y,z+1));
32    end
33    /* vecino atrás */
34    if matrizVoxeles (semilla.x,semilla.y,semilla.z-1)==0 then
35    |   matrizVoxeles (semilla.x,semilla.y,semilla.z-1)←1;
36    |   pila.push(semilla (x,y,z-1));
37    end
38 end

```

5.3. MAPA DE COLOR DE LA SUPERFICIE GENERADA A PARTIR DE LA DISTRIBUCIÓN




Figura 5.7: Superficie generada a partir de la distribución de color utilizando el software Amira.

1000 En el algoritmo 5.3.4 los colores fueron calculados por vértice. Para asignar el
1001 color al resto del triángulo se utiliza un *shader* que se encarga de interpolarlos.

1002 La Figura 5.8 muestra la pintura *Gala contemplando el Mediterráneo* (1976) a
1003 la cual se le calculará el mapa de color. Las Figuras 5.9 y 5.10 muestran, desde
1004 diferentes perspectivas, el proceso que se sigue para asignar el mapa de color a la
1005 superficie generada a partir de la distribución de color de la pintura. Primero, en
1006 ambas Figuras se muestra la distribución de color con los ejes principales. En segundo
1007 lugar, se muestra la distribución de color rodeada por el elipsoide que mejor ajusta.
1008 Finalmente aparece la superficie con el mapa de color y el elipsoide que mejor se
1009 ajusta.

Algorithm 5.3.4: Algoritmo para calcular el color por vértice

```

1 Function calcMapaColor
   Input: Vertices de la superficie, campo de distancia del elipsoide
   Output: color por vértice
2   /* Obtiene los valores máximo y mínimo de la matriz de
      distancias */
3   max-val ← distanceTransformMatrix.min;
4   max-val ← distanceTransformMatrix.min;
5   /* Por cada vértice en el modelo de la superficie */
6   foreach vertex ∈ bananoidModel do
7     /* Transforma las coordenadas del vértice a su equivalente
       en coordenadas de la matriz de distancia */
8     VoxCoord ← transformInVoxelCoords (vertex);
9     distance ← distanceTransformMatrix (VoxCoord);
10    /* Si la distancia al elipsoide es cero, asigna color
       blanco */
11    if distance == 0 then
12      | color = color (1.0,1.0,1.0)
13    /* Si la distancia es mayor a cero, se encuentra fuera del
       elipsoide, asigna color azul */
14    else if distance > 0 then
15      | atenuacion ← distance/max-val;
16      | /* Mientras más alejado esté el vértice del elipsoide
         más intenso será el tono azul */
17      | color ← color (1-atenuacion,1-atenuacion,1.0)
18    /* el vértice está dentro del elipsoide, asigna color rojo
       */
19    else if distance < 0 then
20      | atenuacion ← distance/max-val;
21      | /* Mientras más hacia el centro del elipsoide esté el
         vértice, más intenso será el tono rojo */
22      | color ← color (1.0,1-atenuacion,1-atenuacion)
23    end
24 end

```


5.3. MAPA DE COLOR DE LA SUPERFICIE GENERADA A PARTIR DE LA DISTRIBUCIÓN






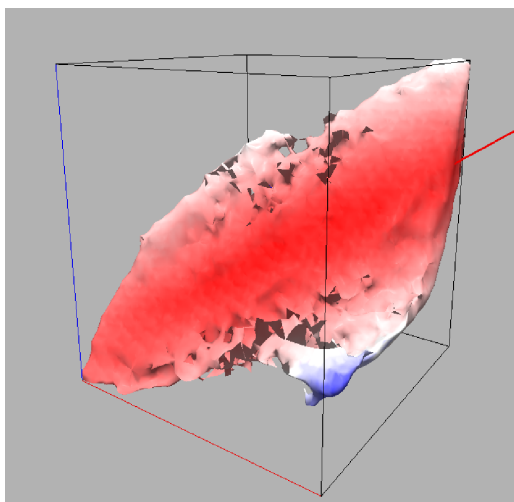
Figura 5.8: *Gala contemplando al Mediterráneo* (1976).




(a) Distribución de color y ejes principales de la pintura en el espacio RGB.



(b) Distribución de color y elipsoide que mejor ajusta.



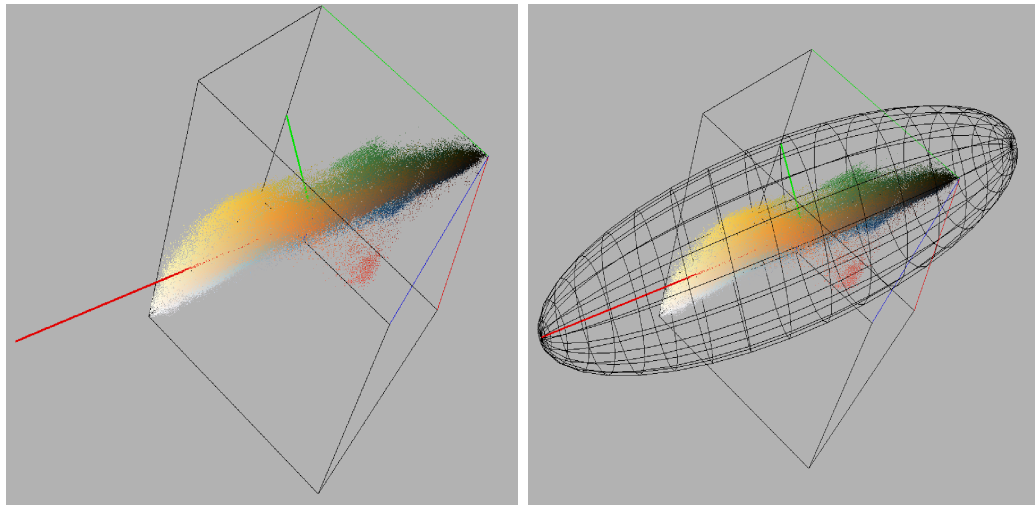
(c) Mapa de color de la superficie generada a partir de la distribución de color.




(d) Mapa de color de la superficie generada a partir de la distribución de color y elipsoide que mejor ajusta.

Figura 5.9: Proceso de cálculo del mapa de color para la pintura *Gala contemplando el Mediterráneo* (1976).

5.3. MAPA DE COLOR DE LA SUPERFICIE GENERADA A PARTIR DE LA DISTRIBUCIÓN



(a) Distribución de color y ejes principales (b) Distribución de color y elipsoide que mejor ajusta de la pintura en el espacio RGB.



(c) Mapa de color de la superficie generada a partir de la distribución de color. (d) Mapa de color de la superficie generada a partir de la distribución de color y elipsoide que mejor ajusta.

Figura 5.10: Proceso de cálculo del mapa de color para la pintura *Gala contemplando el Mediterráneo* (1976).

1010 5.3.4. Características asociadas a la distribución de color y 1011 al elipsoide ajustado

1012 Además de generar el elipsoide ajustado y el mapa de color a cada superficie a
1013 partir de la distribución de color, es posible calcular ciertas características o descrip-
1014 tores que podrían ayudar a describir con mayor precisión o detalle la distribución
1015 de color de una pintura. Éstos descriptores se enumeran a continuación:

1016 Esfericidad del elipsoide

La esfericidad mide qué tan redonda es una forma. La esfericidad es una razón, por lo tanto carece de dimensiones. Esta puede ser calculada para cualquier objeto tridimensional mientras se conozca el área y el volumen de la misma (Robinson, 2017).

La esfericidad se define como sigue:

$$\psi = \frac{\pi^{\frac{1}{3}}(6V_p)^{\frac{2}{3}}}{A_p} \quad (5.12)$$

1017 Donde V_p es el volumen del objeto y A_p es el área.

1018 Dimensión fractal

1019 Utilizando la versión 3D del algoritmo *Box Counting* que se mencionó en el
1020 capítulo 3, se calcula la dimensión fractal de la distribución de color².

1021 Distancia al centroide promedio

1022 Para cada pintura se calcula el centroide o centro de masa de la distribución de
1023 color. Al analizar un grupo de pinturas, se calcula el centroide promedio y poste-
1024 riormente la distancia euclidiana de cada centroide al centroide promedio, con la
1025 finalidad de observar qué tanto varían los centroides de las pinturas estudiadas.

1026 Ángulos de desviación respecto al eje principal promedio

1027 Para todas las pinturas se calculan tres ejes principales, al aplicar la técnica
1028 de **análisis de componentes principales** a la distribución de color. Para cada
1029 pintura se detecta al eje principal con mayor *eigenvalor* (aquel en el que existe
1030 mayor varianza) y se calcula el eje principal promedio para cada grupo de pinturas.
1031 Finalmente, se obtiene el ángulo existente entre el **eje principal promedio** y el
1032 eje principal con mayor *eigenvalor* de cada pintura. El objetivo de este descriptor
1033 es tratar de observar si un pintor varía el uso de color en direcciones similares o
1034 direcciones completamente diferentes.

1035 5.3.5. Histograma de 64 colores

1036 Para tratar de caracterizar el uso de color en cada pintura, en lugar de utilizar
1037 un histograma de 256^3 colores, se generó un histograma con solo 64 colores al dividir
1038 al cubo que define el espacio de color RGB en cuatro partes equidistantes por cada
1039 dimensión, resultando en 4^3 colores.

1040 La Figura 5.11 muestra 4 cortes realizados al espacio RGB. La Figura 5.12 presenta
1041 de manera detallada la subdivisión de cada corte mostrado en la Figura 5.11, para
1042 obtener las 64 regiones mencionadas.

²El algoritmo comienza con un tamaño de caja=256 y finaliza con un tamaño de caja =2.




Figura 5.11: División del espacio RGB en 64 regiones.

1	2	3	4																																																																
<table border="1" style="width: 100%; text-align: center;"> <tr><td>12</td><td>13</td><td>14</td><td>15</td></tr> <tr><td>8</td><td>9</td><td>10</td><td>11</td></tr> <tr><td>4</td><td>5</td><td>6</td><td>7</td></tr> <tr><td>0</td><td>1</td><td>2</td><td>3</td></tr> </table>	12	13	14	15	8	9	10	11	4	5	6	7	0	1	2	3	<table border="1" style="width: 100%; text-align: center;"> <tr><td>28</td><td>29</td><td>30</td><td>31</td></tr> <tr><td>24</td><td>25</td><td>26</td><td>27</td></tr> <tr><td>20</td><td>21</td><td>22</td><td>23</td></tr> <tr><td>16</td><td>17</td><td>18</td><td>19</td></tr> </table>	28	29	30	31	24	25	26	27	20	21	22	23	16	17	18	19	<table border="1" style="width: 100%; text-align: center;"> <tr><td>44</td><td>45</td><td>46</td><td>47</td></tr> <tr><td>40</td><td>41</td><td>42</td><td>43</td></tr> <tr><td>36</td><td>37</td><td>38</td><td>39</td></tr> <tr><td>32</td><td>33</td><td>34</td><td>35</td></tr> </table>	44	45	46	47	40	41	42	43	36	37	38	39	32	33	34	35	<table border="1" style="width: 100%; text-align: center;"> <tr><td>60</td><td>61</td><td>62</td><td>63</td></tr> <tr><td>56</td><td>57</td><td>58</td><td>59</td></tr> <tr><td>52</td><td>53</td><td>54</td><td>55</td></tr> <tr><td>48</td><td>49</td><td>50</td><td>51</td></tr> </table>	60	61	62	63	56	57	58	59	52	53	54	55	48	49	50	51
12	13	14	15																																																																
8	9	10	11																																																																
4	5	6	7																																																																
0	1	2	3																																																																
28	29	30	31																																																																
24	25	26	27																																																																
20	21	22	23																																																																
16	17	18	19																																																																
44	45	46	47																																																																
40	41	42	43																																																																
36	37	38	39																																																																
32	33	34	35																																																																
60	61	62	63																																																																
56	57	58	59																																																																
52	53	54	55																																																																
48	49	50	51																																																																

Figura 5.12: Descripción detallada de la división del espacio RGB en 64 regiones.

1043 5.3.6. Brillo y oscuridad en una pintura

1044 Con el objetivo de tratar determinar si un artista utiliza tonos claros, medios
 1045 u oscuros en sus pinturas, a partir del canal *value* del espacio **HSV** se generó un
 1046 histograma de 5 *bins*: **región muy oscura** [0-50], **región oscura** [51-101], **región**
 1047 **media** [102-152], **región brillante** [153-203], **región muy brillante** [204-255].

1048 5.3.7. Error cuadrático medio

El error cuadrático medio es una métrica que permite medir qué tan bien se ajusta un modelo a la realidad. Utilizando este concepto y con ayuda del campo de distancia se calcula el **RSME** (*root square mean error*) para cada superficie generada a partir de la distribución de color respecto al elipsoide ajustado. Lo anterior permite cuantificar qué tan bien se ajusta el modelo a cada superficie y puede mostrar diferencias significativas entre los pintores estudiados. El **RSME** se define como sigue:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{n}} \quad (5.13)$$

1049 Donde \hat{Y} es el valor de la predicción y Y es el valor real.

1050 5.4. Imágenes basadas en los descriptores de GLCM

1051 En (Hall-Beyer, 2017) se describe la metodología para generar una imagen basada
1052 en alguno los descriptores ³ obtenidos a partir de la matriz de co-ocurrencia. Generar
1053 esta imagen permite obtener la descripción textural por cada pixel en cierta región
1054 o vecindario.

1055 El proceso para generar las imágenes a partir de los descriptores se presenta a
1056 continuación:

- 1057 1. Reducir los niveles de gris presentes en la imagen a analizar (re-cuantización).
- 1058 2. Definir una ventana o región de interés y sus dimensiones. Para facilitar los
1059 cálculos, se recomienda que las dimensiones de la ventana sean impares.
- 1060 3. Hacer coincidir una de las esquinas de la ventana con el origen de la imagen a
1061 analizar.
- 1062 4. Calcular la matriz de co-ocurrencia considerando solo los pixeles que están
1063 dentro de la región definida por la ventana.
- 1064 5. Calcular los descriptores asociados a la matriz de co-ocurrencia.
- 1065 6. Asignar el valor del descriptor al pixel central de la región de interés.
- 1066 7. Desplazar la ventana un pixel y repetir el proceso desde el punto número dos
1067 hasta recorrer la imagen completa.

1068 La Figura 5.13 ilustra de manera sencilla el procedimiento anterior.

³También conocida como imagen paramétrica, dado que en la literatura un descriptor suele denominarse “parámetro“. Sin embargo, al convertirse en atributo local se puede decir que juega el rol de un parámetro cuya variación se visualiza.

Example: For a 5x5 window, the outer 2 rows and columns of the image receive the texture values calculated in row 3 (top edge), column 3 (left edge), row L-2 (bottom edge) and column P-2 (right edge) where P,L are the dimensions in pixels and lines of the original image. For the illustrated image, L=P=10, so values are calculated from row 3 and column 3 through row 8 and column 8.

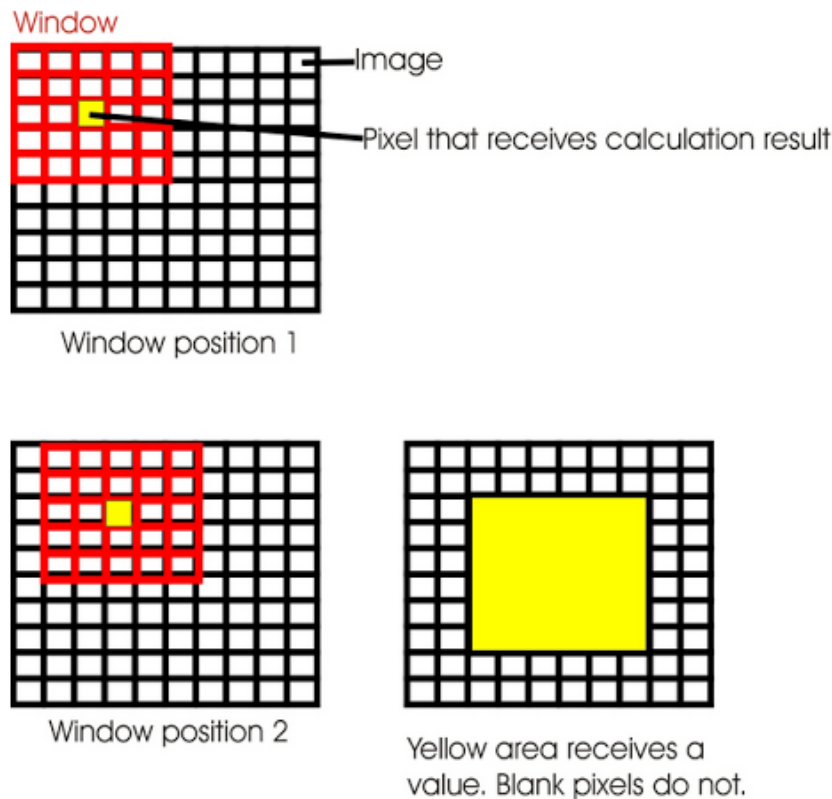


Figura 5.13: Cálculo de una imagen basada en los descriptores asociados a la GLCM. Imagen tomada de (?).

1069 5.4.1. Recuantización

1070 En el caso particular de una **imagen en niveles de gris**, el proceso de recuan-
 1071 tización se refiere a disminuir dichos niveles. Realizar el proceso de recuantización
 1072 a una imagen antes de calcular la matriz de co-ocurrencia es una práctica común,
 1073 ya que mientras mayor sea el número de niveles de gris utilizado, los cambios en la
 1074 textura, son más difíciles de identificar (Renzetti and Zortea, 2011).

1075 Otro aspecto a considerar, es que mientras mayor sea la cantidad de niveles de gris,
 1076 el análisis será más sensible al ruido y el costo computacional de crear matrices con
 1077 elevados niveles de gris es bastante alto.

1078 Comúnmente se utilizan 16 niveles de gris para calcular la matriz de co-ocurrencia.

1079 Las Figuras 5.14 y 5.15 muestran el proceso de recuantización de una imagen, en
 1080 este caso, la *Monalisa*. En la Figura 5.14 se aprecia la pintura original y la reducción
 1081 de niveles de gris en 128, 64 y 32 niveles de gris. A simple vista es complicado
 1082 apreciar diferencias notables entre las distintas versiones. A diferencia de la Figura
 1083 5.15 donde se muestran las versiones de 16, 8, 4 y 2 niveles de gris. En este caso, se
 1084 aprecian con mayor facilidad las diferencias respecto a la pintura original, debido al

1085 reducido número de niveles de gris utilizados para representar los valores de cada
1086 pixel.



(a) Original.



(b) 128 niveles de gris.



(c) 64 niveles de gris.



(d) 32 niveles de gris.

Figura 5.14: Pintura original y reducciones a 128, 64 y 32 niveles de gris.



(a) 16 niveles de gris.

(b) 8 niveles de gris.



(c) 4 niveles de gris.

(d) 2 niveles de gris.

Figura 5.15: Pintura original y reducciones a 128, 64 y 32 niveles de gris.

Algorithm 5.4.1: Algoritmo que reduce los niveles de gris de una imagen.

```

1 Function ReduceNivelesdeGris
   Input: Imagen a cuantizar, niveles de gris deseados (potencia de 2)
   Output: Imagen cuantizada
2   /* Calcula los bits de desplazamiento para calcular el nuevo
      valor */
3   bitsDesplazados  $\leftarrow 8 - \log(\text{grayLevels}) / \log(2)$ ;
4   grayLevels  $\leftarrow$  grayLevels-1;
5   foreach pixel in Imagen do
6     valorActual  $\leftarrow$  Imagen (pixel);
7     /* Realiza un corrimiento de bits hacia la izquierda y un
        AND a nivel de bits. Vuelve a realizar un corrimiento
        hacia la derecha para obtener el nuevo nivel de gris */
8     nuevoValor  $\leftarrow$  (valorActual &(grayLevels
        <<bitsDesplazados)) >> bitsDesplazados;
9     Imagen (pixel)  $\leftarrow$  nuevoValor;
10  end
11 end

```

1087 5.4.2. Cálculo de la imagen basada en los descriptores de la 1088 GLCM

1089 En el algoritmo 5.4.2 se muestra cómo crear una imagen de textura a partir de
1090 cualquiera de los descriptores obtenidos de la **GLCM**. Primero se reducen los niveles
1091 de gris de la imagen original como se muestra en el algoritmo 5.4.1. Se define una
1092 ventana de análisis y se extraen, de la imagen que ha sido cuantizada, los píxeles
1093 correspondientes a la región demarcada por la ventana. Se calcula la **GLCM** sobre
1094 dicha región y se obtiene el descriptor deseado de esa matriz de co-ocurrencia en
1095 particular. Se asigna el valor del descriptor al píxel central de la región de interés.
1096 Finalmente, se repite el proceso para toda la imagen, deslizando la ventana un píxel
1097 a la vez.

1098 La Figura 5.16 muestra la pintura original y las imágenes de textura basada
1099 en tres descriptores: contraste, correlación y entropía. La figura 5.17 muestra los
1100 descriptores restantes: correlación, ASM y, contraste.

Algorithm 5.4.2: Algoritmo que la imagen de textura basada en los descriptores obtenidos a partir de la GLCM.

```

1 Function createImageTexture
   Input: Tamaño de ventana, imagen original, vector de dirección,
           descriptor deseado
   Output: Imagen creada a partir de los descriptores
2  /* Cuantiza la imagen original a los niveles de gris deseados
   */
3  ImagenCuantizada ← ReduceNivelesdeGris (imagenOriginal,nivelesGris);
4  /* por cada pixel en la imagen cuantizada, extraer la región
   de interés definida por la ventana. Calcula la GLCM y el
   descriptor deseado */
5  foreach pixel in ImagenCuantizada do
6     /* Obtiene la región de interés a través de las
       dimensiones definidas para la ventana de análisis,
       teniendo como punto central las coordenadas del pixel
       actual */
7     ROI ← ImagenCuantizada (ventana.x,ventana.y, pixel);
8     /* Calcula la GLCM solo para los pixeles definidos en ROI,
       con la dirección de dir */
9     GLCM ← calcGLCM (ROI,dir);
10    /* Calcula el descriptor elegido para la GLCM */
11    descriptor ← calcDescriptor (GLCM,nombreDescriptor);
12    /* Asigna el valor del descriptor a una matriz con las
       mismas dimensiones que la imagen original, en la
       coordenada de pixel */
13    ImagenTextura (pixel)←descriptor;
14  end
15 end

```



(a) Portrait of Mademoiselle Sicotg (1865).

(b) Textura creada a partir de la homogeneidad.



(c) Textura creada a partir de la entropía.

(d) Textura creada a partir de la disimilitud.

Figura 5.16: Pintura original e imágenes de textura obtenidas a partir de los descriptores calculados a la GLCM.



(a) *Portrait of Mademoiselle Sicotg* (1865). (b) Textura creada a partir de la correlación.




(c) Textura creada a partir del segundo momento angular (ASM). (d) Textura creada a partir del contraste.

Figura 5.17: Pintura original e imágenes de textura obtenidas a partir de los descriptores calculados a la GLCM.

1101 5.5. Imágenes paramétricas

1102 Como si se tratarán de los canales que componen a una imagen a color, las
1103 imágenes de textura creadas en la sección anterior, se unirán mediante combinaciones
1104 diversas, dando como resultado imágenes de textura a color. Con lo anterior, se
1105 podrá efectuar un análisis similar al que se realizó para la distribución de color
1106 de cada pintura. Además, se tiene como objetivo tratar de determinar cuáles son
1107 los descriptores menos correlacionados entre sí, lo que permitirá escoger a aquellos
1108 descriptores que mejor describan la **distribución textural**.

1109 La Figura 5.18 muestra la pintura original y tres imágenes de textura obtenidas
1110 a partir de la combinación de tres imágenes de textura basadas en descriptores
1111 diferentes.

(a) *Festival de las flores* (1925).

(b) Imagen paramétrica creada a partir de la disimilitud, entropía y homogeneidad.

(c) *Araña de la noche..Esperanza* (1940).

(d) Imagen paramétrica creada a partir de la disimilitud, entropía y homogeneidad.

Figura 5.18: Pintura original y texturas a color obtenidas de la combinación de disimilitud, entropía y homogeneidad.

1112 5.6. Histogramas basados en patrones binarios lo- 1113 cales

1114 Es posible calcular un histograma al contar las ocurrencias de los distintos **LBP**
1115 calculados para una imagen. Si se calculan **LBP** para diversas imágenes, y al mismo
1116 tiempo, se obtienen los histogramas de **LBP** de cada imagen, es posible comparar
1117 las imágenes a través de métricas que permiten conocer la similitud entre dos histo-
1118 gramas distintos.

1119 El propósito de calcular histogramas de **Local Binary Patterns** en pinturas, es
1120 compararlas y determinar si para las obras elaboradas por un solo pintor, existe
1121 similitud entre los histogramas obtenidos a partir de cada pintura estudiada.

1122 5.6.1. Histograma de patrones binarios locales

1123 El algoritmo 5.6.1 muestra el proceso para calcular el histograma de patrones.


1124 La Figura 5.19 muestra a la *Monalisa* y al histograma de **LBP** asociado. En el
1125 algoritmo 5.6.1 que fue utilizado para generar los histogramas de todas las pinturas
1126 analizadas, se consideraron solamente **ocho vecinos** con un **radio=1**.

Algorithm 5.6.1: Algoritmo que el histograma LBP para una imagen imagen.


```

1 Function CalculaLBP
   Input: Imagen
   Output: Histograma LBP
2 foreach pixel in imagen do
3     /* Variable que contendrá el código LBP, inicializada en
       cero */
4     codigo ← 0;
5     /* Obtiene los ocho vecinos que reodean al pixel */
6     vecino 0 ← imagen (vecinoSur);
7     vecino 1 ← imagen (vecinoSureste);
8     vecino 2 ← imagen (vecinoEste);
9     vecino 3 ← imagen (vecinoNoreste);
10    vecino 4 ← imagen (vecinoNorte);
11    vecino 5 ← imagen (vecinoNoroeste);
12    vecino 6 ← imagen (vecinoOeste);
13    vecino 7 ← imagen (vecinoSurOeste);
14    /* a través de corrimientos de bits y una operación
       Ó'lógica con cada vecino, genera el código del patrón
       */
15    codigo ← (pixel ≥ vecino 0) << 0 | codigo;
16    codigo ← (pixel ≥ vecino 1) << 1 | codigo;
17    codigo ← (pixel ≥ vecino 2) << 2 | codigo;
18    codigo ← (pixel ≥ vecino 3) << 3 | codigo;
19    codigo ← (pixel ≥ vecino 4) << 4 | codigo;
20    codigo ← (pixel ≥ vecino 5) << 5 | codigo;
21    codigo ← (pixel ≥ vecino 6) << 6 | codigo;
22    codigo ← (pixel ≥ vecino 7) << 7 | codigo;
23    /* Cuenta cada ocurrencia de codigo */
24    Histograma (codigo) += 1;
25 end
26 end

```



(a) Monalisa.



(b) Histograma LBP.

Figura 5.19: Monalisa e histograma de LBP asociado. Para calcular este histograma se consideraron 8 vecinos con un radio=1.

1127 5.6.2. Histograma de patrones binarios locales uniformes

1128 Con la finalidad de explorar versiones distintas y tal vez, de obtener resultados
 1129 más precisos se consideró también el cálculo del histograma de ULBP. El algoritmo
 1130 para calcular este histograma es bastante similar al algoritmo 5.6.1. La diferencia
 1131 radica en que el histograma para ULBP contiene únicamente 59 bins, 58 de ellos para
 1132 los patrones uniformes y el número 59 para los patrones no uniformes. El algoritmo
 1133 5.6.2 fue utilizado para calcular el histograma de ULBP, considerando **ocho vecinos**
 1134 y **radio=1**.


1135 En la Figura 5.20 se observa a la *Monalisa* y al histograma ULBP que fue gene-
 1136 rado a partir de la misma.

Algorithm 5.6.2: Algoritmo que el histograma ULBP para una imagen imagen.

```

1 Function CalculaULBP
   Input: Imagen
   Output: Histograma ULBP
2 foreach pixel in imagen do
3     /* Variable que contendrá el código LBP, inicializada en
       cero */
4     codigo ← 0;
5     /* Obtiene los ocho vecinos que rodean al pixel */
6     vecino 0 ← imagen (vecinoSur);
7     vecino 1 ← imagen (vecinoSureste);
8     vecino 2 ← imagen (vecinoEste);
9     vecino 3 ← imagen (vecinoNoreste);
10    vecino 4 ← imagen (vecinoNorte);
11    vecino 5 ← imagen (vecinoNoroeste);
12    vecino 6 ← imagen (vecinoOeste);
13    vecino 7 ← imagen (vecinoSurOeste);
14    /* a través de corrimientos de bits y una operación
       Ó'lógica con cada vecino, genera el código del patrón
       */
15    codigo ← (pixel ≥ vecino 0) << 0 | codigo;
16    codigo ← (pixel ≥ vecino 1) << 1 | codigo;
17    codigo ← (pixel ≥ vecino 2) << 2 | codigo;
18    codigo ← (pixel ≥ vecino 3) << 3 | codigo;
19    codigo ← (pixel ≥ vecino 4) << 4 | codigo;
20    codigo ← (pixel ≥ vecino 5) << 5 | codigo;
21    codigo ← (pixel ≥ vecino 6) << 6 | codigo;
22    codigo ← (pixel ≥ vecino 7) << 7 | codigo;
23    /* Si el código es uniforme, elige el bin al que pertenece
       */
24    if codigo es uniforme then
25        | bin ← selectBin (code);
26    end
27    /* Si el código es no uniforme, se elige al bin 58 para
       almacenarlo */
28    else
29        | bin ← 58;
30    end
31    HistogramaULBP [bin] ← + = 1;
32 end
33 end

```



(a) Monalisa.

(b) Histograma ULBP.

Figura 5.20: Monalisa e histograma de ULBP asociado.

1137 5.6.3. Histograma de patrones binarios locales dominantes

1138 En el algoritmo 5.6.3 se muestra el proceso para obtener a los patrones domi-
1139 nantes.

Algorithm 5.6.3: Algoritmo que obtiene los *DLBP* de una imagen.

```

1 Function CalculaDLBP
   Input: Imagen
   Output: Vector que contiene los DLBP
2   totalOcurrencias ←0;
3   index ←0;
4   /* Primero calcula de manera tradicional el histograma LBP
      como se vio en el algoritmo 5.6.1 */
5   histogramaLBP ←calculaLBP (imagen);
6   /* ordena de manera decreciente el histograma de LBP */
7   histogramaOrdenado ←leftarrowordenaHistograma (histogramaLBP);
8   /* Obtiene los patrones que conforman el 80% del total de
      ocurrencias de patrones */
9   while totalOcurrencias  $\geq 0.8$  do
10    /* obtiene el patron */
11    patron ←histogramaOrdenado [index ];
12    /* obtiene y acumula la ocurrencia del patron */
13    totalOcurrencias +=histogramaLBP [patron ];
14    /* agrega el patron al vector DLBP */
15    DLBPvector.push(patron);
16  end
17 end

```


1140 Capítulo 6

1141 Experimentos y Resultados

1142 En este capítulo se presentan los resultados obtenidos tras analizar las pinturas
1143 de artistas como **Diego Rivera, Salvador Dalí, Leonardo Da Vinci, Pablo Pi-**
1144 **casso, Vincent Van Gogh, Claude Monet y, Pierre-Auguste Renoir.** Para
1145 determinar si los pintores estudiados conservan características similares en cada una
1146 de sus pinturas, las pinturas fueron agrupadas por autor para su análisis. Como ya
1147 se había mencionado, las características calculadas fueron **esfericidad del elipsoi-**
1148 **de ajustado, dimensión fractal de la distribución de color, eigenvalores**
1149 **y eigenvectores de la distribución de color, centroide de la distribución**
1150 **de color**, entre otras. Se presentan gráficas con los promedios por pintor de cada
1151 característica, así como la desviación estándar con la finalidad de tener un número
1152 que los represente a y funcione como referencia para compararlos.

1153 Para tratar de caracterizar la paleta de colores utilizada de cada pintor estudiado,
1154 el espacio RGB fue dividido en 64 regiones. A partir de estas regiones se genera un
1155 histograma para cada pintura revisada. Al graficar los histogramas, y compararlos.
1156 se puede observar si un pintor tiende a utilizar colores similares o muy distintos al
1157 elaborar sus pinturas.

1158 En el caso del análisis textural, se presentan los valores promedio de los des-
1159 criptores calculados a partir de la **matriz de co-ocurrencia** para cada pintor así
1160 como las desviaciones estándar. Los datos obtenidos serán de ayuda para tratar de
1161 caracterizar a los pintores estudiados, además servirán también, para compararlos
1162 entre ellos. Se consideró también el uso de **local binary patterns** y dos variantes
1163 de los mismos: **unifom local binary Patterns** y **dominant local binary pat-**
1164 **terns.** Para el caso de **LBP** y **ULBP** se generaron histogramas de los patrones y,
1165 utilizando métricas de comparación de histograma (**chi cuadrada**) se compararon
1166 los histogramas de cada pintura. Se muestran el promedio de dichas comparaciones
1167 y la desviación estándar de las mismas.

1168 Como se detalló en el capítulo 4 los **DLBP** son aquellos que tienen mayor número
1169 de ocurrencias y representan el 80 por ciento de los patrones presentes en una imagen.
1170 En este capítulo se presenta el número de patrones promedio que requiere cada autor
1171 para realizar su trabajo, así como las desviaciones estándar respectivas.

1172 Además de los pintores, se formaron dos grupos de pinturas e imágenes para
1173 tener puntos de comparación. El primer grupo, llamado **Imágenes Aleatorias** se
1174 conforma de 22 imágenes (no pinturas) elegidas al azar. En este grupo aparecen

1175 fotografías de paisajes, retratos, fotografías de animales, gradientes de color e incluso
 1176 imágenes con ruido a color. El objetivo de este grupo es tener imágenes con poca o
 1177 nula relación entre ellas. El segundo grupo, llamado **Pinturas Combinadas** consta
 1178 de 14 pinturas. Para este grupo se eligieron dos pinturas por cada pintor estudiado.
 1179 El propósito de este grupo es similar al del primer grupo, observar el comportamiento
 1180 de obras de distintos pintores y comparar los resultados con los obtenidos para cada
 1181 artista.

1182 6.1. Resultados análisis de color

1183 6.1.1. Descriptores promedio

1184 En el cuadro 6.1 se muestran las características promedio calculadas para cada
 1185 pintor. También se incluyen los grupos de **Aleatorias** y **Combinadas**. En el cuadro
 1186 6.2 se muestran las desviaciones estándar de cada característica promedio calculada.
 1187

	Esfericidad	Dimensión Fractal	Distancia al centroide	Ángulo de desviación	RSME
Aleatorias	0.908649	2.41082	0.27997	19.0015802	4.7836
Dalí	0.839501	2.32852095	0.2237	9.4631777	3.3034
Da Vinci	0.713459	2.207994	0.124406	8.1139	5.3964
Diego Rivera	0.770383143	2.2889	0.144422	6.5099	4.7368
Combinadas	0.794805	2.337982	0.211798	10.3854	4.7767
Claude Monet	0.756061	2.3405	0.226527	8.1494	4.8212
Picasso	0.860328	2.4661	0.16981	8.465702	5.5971
Renoir	0.779686	2.301	0.180666	6.305831	4.5217
Van Gogh	0.8161	2.22	0.214513	19.9804	7.1885

Cuadro 6.1: Características promedio de cada grupo de pinturas.

1188 Las Figuras 6.1, 6.2, 6.3, 6.4, 6.5 muestran los diagramas de caja asociados a cada
 1189 parámetro calculado y permiten observar las diferencias o similitudes que existen
 1190 entre los pintores.

1191 **Esfericidad** Al observar las distintas pinturas estudiadas y los resultados mostrados
 1192 en la Figura 6.1 se notó lo siguiente: mientras mayor sea el índice de esfericidad
 1193 del elipsoide ajustado asociado a cada distribución de color, los colores utilizados
 1194 en las pinturas serán más saturados, debido a que los colores utilizados se alejan
 1195 de la diagonal del cubo RGB. Lo anterior explica porqué las pinturas de **Leonardo**
 1196 **Da Vinci** son las que presentan menor índice de **esfericidad**, ya que su paleta de
 1197 colores no suele incluir colores muy saturados. Por otro lado, se puede ver en la

	Esfericidad	Dimensión Fractal	Distancia al centroide	Ángulo de desviación	RSME
Aleatorias	0,070025	0.231711	0.17773185	16.403	1.411
Dalí	0.0754823	0.113673	0.12377	7.252408	1.06079
Da Vinci	0.0653785	0.09084	0.080484	6.7441459	1.768
Diego Rivera	0.045161	0.087801	0.107767	6.5947	1.04299
Combinadas	0.08774	0.10363	0.12564	6.8173	2.4319
Monet	0.0793	0.1264	0.11537	4.4436	2.1898
Picasso	0.07781	0.09457	0.10608	5.9899	2.5604
Renoir	0.064603	0.1108	0.09009	3.498053	1.7472
Van Gogh	0.12577	0.207218	0.14908	23.86267	4.2839

Cuadro 6.2: Desviaciones estándar de los descriptores calculados a cada grupo de pinturas.

1198 gráfica de la Figura 6.1 que **Salvador Dalí** y **Pablo Picasso** presentan los mayores
1199 valores de **esfericidad**, esto se debe a que en sus trabajos, generalmente, utilizan
1200 colores más saturados en comparación con **Leonardo Da Vinci**. Es interesante
1201 observar también las desviaciones estándar de cada pintor. En el cuadro 6.2 es claro
1202 que **Diego Rivera** es quien presenta menor desviación estándar entre todos los pin-
1203 tores y grupos de pintura estudiados, mientras que la mayor desviación estándar se
1204 presenta con **Vincent Van Gogh**, lo cual también puede verse de manera gráfica
1205 en la Figura 6.1. De acuerdo a lo anterior, se puede concluir que en la mayoría de las
1206 pinturas analizadas, **Diego Rivera** se muestra constante en el grado de saturación
1207 que utiliza en sus colores, mientras que **Vincent Van Gogh** puede tener pinturas
1208 con colores saturados así como pinturas con baja saturación.

1209

1210 **Leonardo Da Vinci** y **Pierre-Auguste Renoir** también presentan valores
1211 pequeños de desviación estándar, y eso se puede observar en el grado de saturación
1212 de color que utilizan en sus distintos trabajos.




Figura 6.1: Gráfica de cajas asociada al parámetro esfericidad.

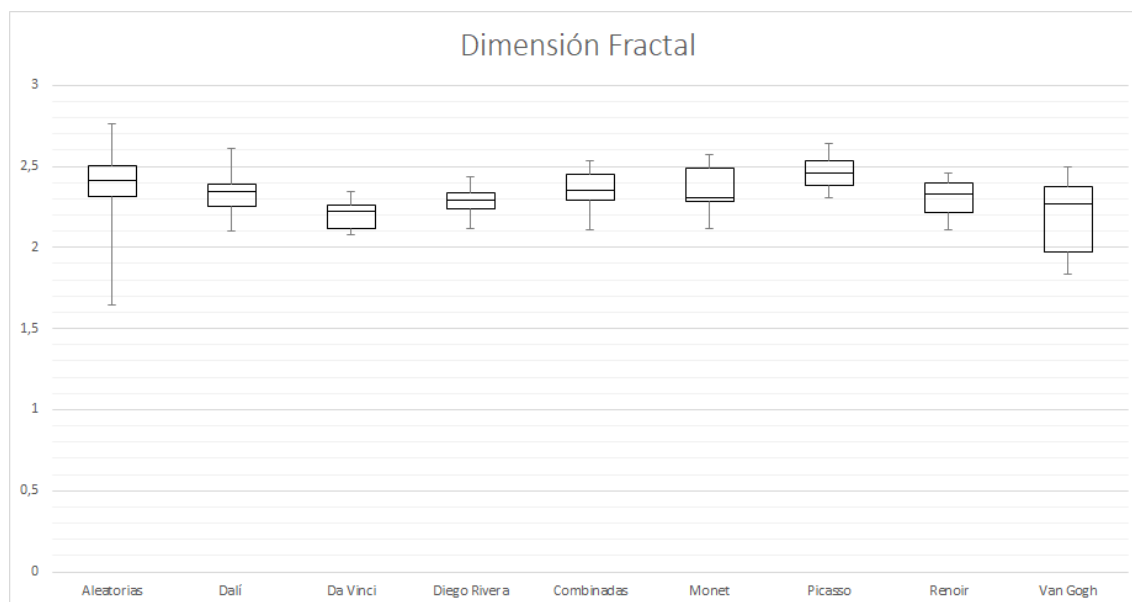


Figura 6.2: Gráfica de cajas asociada a la dimensión fractal.

1213 **Dimensión fractal** En el cuadro 6.2 se aprecia que el grupo **Aleatorias** presen-
 1214 ta la mayor desviación estándar entre todos los grupos estudiados. Dado que las
 1215 imágenes en este grupo no son pinturas y no existe relación entre ellas es normal
 1216 que existan variaciones tan grandes.

1217 Por otro lado, el bajo valor de **dimensión fractal** presente en los trabajos de **Da**
 1218 **Vinci** así como la poca variación de la misma a lo largo de su trabajo, es probable

1219 que se deba al uso de técnicas como el *claroscuro*¹ y *esfumado*²; a que la mayoría de
 1220 sus trabajos son retratos o muestran a la Figura humana, por lo que **Da Vinci** se
 1221 limitaba al uso de ciertos colores. **Diego Rivera** es el pintor que presenta el menor
 1222 valor de desviación estándar, lo cual puede observarse gráficamente en la Figura 6.2.

1223 Con un valor similar de **dimensión fractal** aparece **Vincent Van Gogh**, sin
 1224 embargo, es el que mayores variaciones de este parámetro presenta en sus pinturas.
 1225 Lo que significa que **Van Gogh** puede presentar pinturas en donde exista preferencia
 1226 a ciertos colores o puede presentar pinturas con distribución de color más uniforme.

1227 Caso contrario es el de **Pablo Picasso**, quien presenta la **dimensión fractal**
 1228 más elevada de todos los grupos de pintura estudiados, así como poca variabilidad
 1229 de la misma. Se puede decir entonces, que la paleta de colores utilizada por **Picasso**
 1230 es bastante uniforme, no muestra preferencia de un color sobre otro en su trabajo y,
 1231 mantiene ese estilo en la mayoría de sus pinturas.

1232 Cabe destacar, que al contrario de **Da Vinci** y **Diego Rivera**, **Vincent Van**
 1233 **Gogh** ha mostrado el valor más alto de variabilidad, lo que demuestra que no existe
 1234 mucha relación entre las paletas de color utilizadas para cada una de sus pinturas.

1235 **Distancia al centroide** El objetivo de este parámetro es tratar de caracterizar el
 1236 uso de color de cada pintor. Es decir, se trata de comprobar si la selección de colores
 1237 es similar en los trabajos de un pintor.




Figura 6.3: Gráfica de cajas asociada a la distancia promedio al centroide promedio.

1238 En el cuadro 6.2 se observa que el grupo **Aleatorias** es el que presenta la mayor

¹ *Chiaroscuro*. Técnica de pintura renacentista que permite plasmar profundidad a través de gradaciones de luz y sombra (*Chiaroscuro*, n.d.)

² *Sfumato*. Técnica de sombreado, que permite transiciones sutiles entre diferentes líneas, colores y tonos (*Chiaroscuro*, n.d.).

1239 distancia al centroide y la mayor desviación estándar. Al ser un grupo *control*, resulta
 1240 un comportamiento esperado. El segundo grupo *control*, **Combinadas**, también
 1241 muestra un valor de distancia alto, respecto al resto. Sin embargo, es comparable
 1242 al mostrado por **Monet**, **Dalí** y **Van Gogh**. Nuevamente, **Da Vinci** presenta los
 1243 valores más pequeños, tanto de distancia al centroide como de desviación estándar.
 1244 Esto podría significar que **Da Vinci**, debido a su estilo, y al uso de técnicas como
 1245 *claroscuro* y *sfumato*, utiliza colores similares en cada una de sus pinturas. Por otra
 1246 parte, el resto de los artistas estudiados, muestran comportamientos más flexibles
 1247 respecto a la elección de colores que componen cada una de sus pinturas.

1248 **Ángulo de desviación** En el cuadro 6.2 se observa que en el grupo **Aleatorias**
 1249 y **Van Gogh** son los que presentan mayor desviación respecto al eje principal pro-
 1250 medio así como mayor varianza. Para **Van Gogh**, esto significa que la manera en
 1251 que el color de sus obras se encuentra distribuido en el espacio de color cambia
 1252 radicalmente de una pintura a otra. El grupo **Combinadas** también presenta un
 1253 valor alto respecto al resto de los pintores, lo cual es normal ya que está conformado
 1254 por pinturas de diverso artistas. Por otra parte **Diego Rivera** y **Renoir** son los
 1255 que muestran menor ángulo de desviación respecto al eje principal promedio. Esto
 1256 significa que la dirección en que se distribuye el color en el espacio RGB para estos
 1257 dos pintores es bastante similar en cada una de sus pinturas. Comportamiento pare-
 1258 cido presentan el resto de los pintores, aunque con ángulos de desviación ligeramente
 1259 mayores.




Figura 6.4: Gráfica de cajas asociada al ángulo de desviación promedio respecto al eje principal promedio.

1260 **RSME** Como se vio en el capítulo 5, se calculó el RSME para cada pintura y se
 1261 obtuvo el promedio de cada pintor, los resultados obtenidos se muestran en la gráfica
 1262 de la Figura 6.5

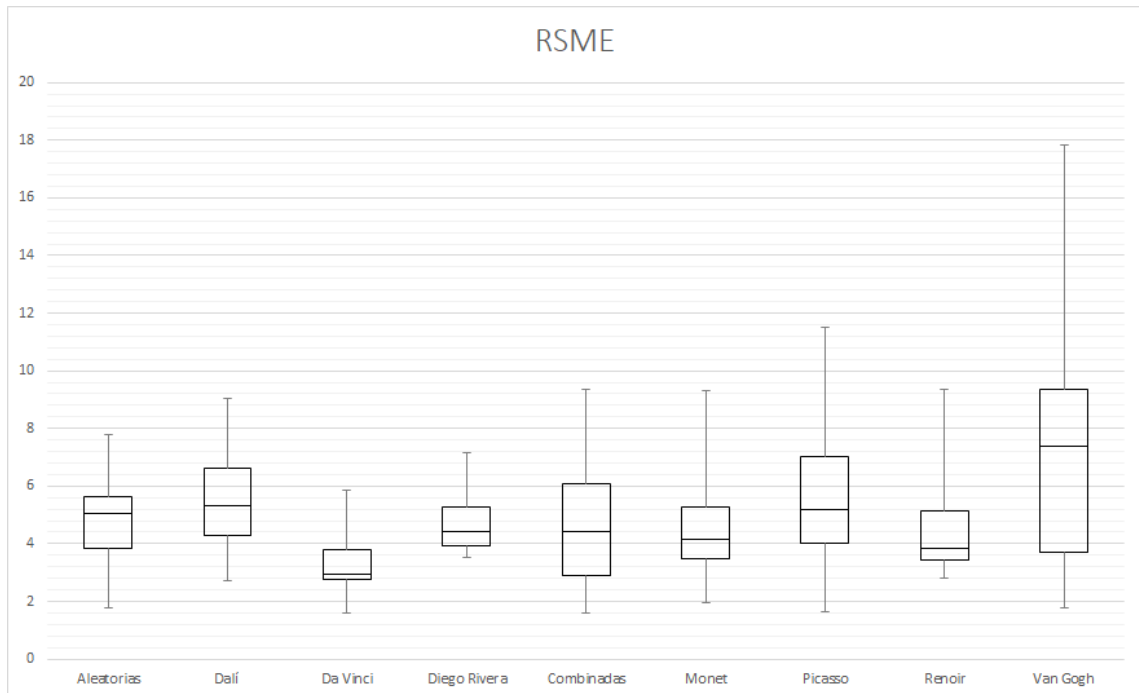


Figura 6.5: Gráfica de cajas asociada a RMSE .

1263 Para este descriptor se observa nuevamente que **Van Gogh** destaca y presenta
 1264 el valor más alto. Esto significa que debido a la naturaleza y forma de la distribución
 1265 de color de sus pinturas, el elipsoide se ajusta en menor medida respecto al resto de
 1266 los pintores, considerando un ajuste ideal, el valor de RSME sería igual a cero. De
 1267 la gráfica, se puede observar que el resto de los pintores muestran comportamiento
 1268 similar entre ellos, mientras que **Salvador Dalí** es el que mejor ajuste tiene.

1269 6.1.2. Colores más usados

1270 A continuación se presentan los histogramas obtenidos para cada pintor tras
 1271 dividir el espacio RGB en 64 regiones. Se muestran los histogramas de todas las
 1272 pinturas o imágenes pertenecientes a cada grupo o pintor en una sola gráfica. El
 1273 objetivo es tratar de observar si cada pintor utiliza el color de manera similar en
 1274 cada una de sus obras o, por el contrario, los colores son distintos en cada una de
 1275 ellas. Los grupos *control*, **Aleatorias** y **Combinadas** servirán para observar los
 1276 resultados en imágenes que parecen no tener nada en común.




Figura 6.6: Histogramas de las imágenes pertenecientes a Aleatorias.




Figura 6.7: Histogramas de las pinturas de Salvador Dalí.




Figura 6.8: Histogramas de las pinturas de Leonardo Da Vinci.




Figura 6.9: Histogramas de las pinturas de Diego Rivera.




Figura 6.10: Histogramas de pinturas de los diferentes artistas estudiados.




Figura 6.11: Histogramas de pinturas de Claude Monet.




Figura 6.12: Histogramas de pinturas de Pablo Picasso.




Figura 6.13: Histogramas de pinturas de Pierre-Auguste Renoir.




Figura 6.14: Histogramas de pinturas de Vincent Van Gogh.

1277 Al observar los histogramas de **Aleatorias** (Figura 6.6) e incluso, el de **Combi-**
 1278 **nadas** (Figura 6.10) se perciben desordenados, sin mostrar algún patrón repetitivo
 1279 en los colores que las componen. **Picasso**, **Van Gogh** y **Dalí** también muestran
 1280 histogramas bastante desordenados, por lo que se puede concluir que no eran cons-
 1281 tantes en el uso de color cuando creaban cada una de sus pinturas. Por otra parte,
 1282 los histogramas de **Da Vinci** (Figura 6.8), **Renoir** (Figura 6.13) y, **Diego Rivera**
 1283 (Figura 6.9) parecen seguir cierto patrón en el uso de color, por lo que se puede
 1284 afirmar que estos pintores solían utilizar colores similares cuando creaban cada una
 1285 de su obras.

1286 6.1.3. Brillo y oscuridad de una pintura

1287 En la siguientes Figuras se muestran los histogramas del parámetro $value^3$ de las
 1288 pinturas asociadas a cada autor y de las que los grupos de comparación **Aleatorias**
 1289 y **Combinadas**.


1290 Para generar dichos histogramas se consideraron 5 clases únicamente:

- 1291 ■ Muy oscuro [0-50].
- 1292 ■ Oscuro [51- 101].
- 1293 ■ Medio [102-152].
- 1294 ■ Claro [153-203].


³El parámetro value pertenece al espacio de color HSV.

1295 ■ Muy claro [204-255].

1296 Los histogramas pertenecientes a cada pintor fueron sobrepuestos en una sola
1297 gráfica de líneas, con la finalidad de tratar de observar alguna tendencia o compor-
1298 tamiento similar entre las pinturas. Además, se incluyeron gráficas radiales, con el
1299 objetivo de visualizar los histogramas de manera distinta a la convencional y tratar
1300 de percibir similitudes entre las pinturas estudiadas.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.15: Histograma del parámetro *value* de Aleatorias.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.16: Histograma del parámetro *value* de las pinturas de Salvador Dalí.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.17: Histograma del parámetro *value* de las pinturas Leonardo Da Vinci.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.18: Histograma del parámetro *value* de las pinturas de Diego Rivera.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.19: Histograma del parámetro *value* de las pinturas de Claude Monet.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.20: Histograma del parámetro *value* de las pinturas de Pablo Picasso.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.21: Histograma del parámetro *value* de las pinturas de **Combinadas**.




(a) Gráfica de líneas.




(b) Gráfica radial.

Figura 6.22: Histograma del parámetro *value* de las pinturas de Pierre-Auguste Renoir.



(a) Gráfica de líneas.



(b) Gráfica radial.

Figura 6.23: Histograma del parámetro *value* de las pinturas de Vincent Van Gogh.

1301 En la Figura 6.17 se muestran los histogramas generados a partir de las pinturas
1302 de **Leonardo Da Vinci**. En 6.17 a) se puede observar que los colores oscuros
1303 abundan en las pinturas **Da Vinci**, ya que es ahí donde se tiene el mayor número
1304 de ocurrencias, disminuyendo de manera gradual hacia los tonos más claros. En 6.17
1305 b) se aprecia que **Da Vinci** muestra estilo similar en la mayoría de sus pinturas.
1306 Este comportamiento, como se había mencionado anteriormente, es muy probable
1307 que se deba al uso del *chiaroscuro*.

1308 De los histogramas mostrados en la Figura 6.16 se observan picos en los tonos muy
1309 oscuros y en los tonos claros y muy claros. Esto hace suponer que el **contraste** es
1310 uno de los elementos presentes en las pinturas de **Dalí**. Sin embargo, los histogramas
1311 generados por la pinturas de **Dalí** no muestran que tuviera algún estilo definido
1312 respecto al uso de colores brillantes y oscuros.

1313 En el caso de **Diego Rivera**, sí se observa comportamiento similar en algunas
1314 de sus pinturas (Figura 6.18) b). Las formas observadas en los histogramas sugieren
1315 que **Rivera** solía utilizar tonos oscuros y tonos muy claros en sus pinturas, logrando
1316 efectos contrastantes. **Renoir**, muestra comportamiento similar al de **Da Vinci**
1317 (6.22 a), en donde algunas de sus pinturas destacan por el uso de tonalidades oscuras
1318 y tonos medios; los tonos claros y muy claros son poco frecuentes en algunas de sus
1319 pinturas.

1320 La Figura 6.20 muestra el comportamiento de **Picasso**, se observa la tendencia al uso
1321 de colores claros y muy claros, con poca presencia de tonos oscuros.

1322 Los casos de **Dalí**, **Van Gogh** y **Monet** son más complejos. En las Figuras 6.16,
1323 6.23 y, 6.19 no se observa algún patrón o comportamiento característico.

1324 6.2. Resultados análisis textural

1325 6.2.1. Matriz de Co-ocurrencia de niveles de gris

1326 Por cada pintura estudiada se generaron seis imágenes basadas en los descriptores
1327 de la **GLCM**. Estos descriptores fueron: **segundo momento (ASM)**, **contraste**,
1328 **correlación**, **disimilitud**, **entropía** y, **homogeneidad**. Para tratar de determinar
1329 qué tan presente está cada uno de los descriptores anteriores en el trabajo de cada
1330 pintor, se obtuvo el promedio⁴ y la desviación estándar de cada descriptor generado.
1331 Los promedios obtenidos se muestran en el cuadro 6.3 y las desviaciones estándar
1332 respectivas se muestran en el cuadro 6.4.

1333 Los parámetros utilizados para llevar a cabo el cálculo de la **GLCM** y los expe-
1334 rimentos, fueron los siguientes:

- 1335 ■ Ocho niveles de gris. Como se menciona en (Hall-Beyer, 2017) calcular la matriz
1336 de co-ocurrencia con pocos niveles de gris reduce la aparición de ceros en las
1337 celdas de la matriz y otorga mayor validez estadística al método, a diferencia
1338 de calcularla con un número elevado de niveles de gris.
- 1339 ■ Relación espacial. Se consideraron tres relaciones con distancia de un pixel: 0

⁴ Los valores de todos los descriptores fueron normalizados al intervalo [0-1] para facilitar las comparaciones.

1340 (0,1), 45(1,1) y 90 (1,0) grados. Los resultados obtenidos no mostraron dife-
 1341 rencias significativas, por esta razón, se presentan solamente los resultados de
 1342 la relación 0 (0,1) grados.

1343 ■ Tamaño de la ventana deslizante. Se eligió una ventana deslizante de 7x7 pi-
 1344 xeles. Dicho tamaño permite describir con mayor detalle las características
 1345 presentes en la textura, a diferencia de una ventana con mayor tamaño.

	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
Aleatorias	0.42	0.9298	0.1163	0.6877	0.2308	0.415
Dalí	0.4989	0.9417	0.0615	0.7647	0.1483	0.3237
Da Vinci	0.5159	0.9644	0.0685	0.7685	0.1732	0.3065
Diego Ri- vera	0.4143	0.9567	0.0891	0.7173	0.2132	0.3886
Combinadas	0.4487	0.9398	0.0909	0.7133	0.2038	0.3674
Monet	0.4074	0.9563	0.0884	0.6888	0.2198	0.3885
Picasso	0.4133	0.9613	0.0807	0.6799	0.2047	0.3843
Renoir	0.4731	0.9702	0.0883	0.7343	0.2028	0.3371
Van Gogh	0.3787	0.9668	0.1253	0.6511	0.262	0.4509

Cuadro 6.3: Descriptores promedio por pintor.

	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
Aleatorias	0.208	0.1349	0.0934	0.1672	0.1416	0.1825
Dalí	0.1322	0.047	0.0243	0.0909	0.051	0.0964
Da Vinci	0.08	0.0309	0.0178	0.0446	0.0374	0.0662
Diego Ri- vera	0.1335	0.0528	0.0344	0.101	0.0589	0.1064
Diversas	0.142	0.111	0.0491	0.0894	0.0795	0.1079
Monet	0.0748	0.0446	0.0289	0.065	0.0474	0.055
Picasso	0.1194	0.0956	0.028	0.0723	0.0544	0.0891
Renoir	0.1374	0.0404	0.0446	0.0836	0.0668	0.0963
Van Gogh	0.1554	0.0354	0.0571	0.1211	0.08442	0.1349

Cuadro 6.4: Desviaciones estándar de los descriptores calculados por pintor.

1346 Segundo momento angular (ASM)

1347 El descriptor ASM mide el orden de los pixeles estudiados. Si los pixeles son
 1348 idénticos, el valor máximo que puede alcanzar el descriptor es uno.

1349 En el cuadro 6.3 se observa que el mayor promedio lo presentan **Da Vinci** y
 1350 **Salvador Dalí** mientras que los promedios más pequeños aparecen en **Aleatorias**
 1351 y **Van Gogh**. En el cuadro 6.4 se puede ver que **Aleatorias** es el grupo con mayor

1352 desviación estándar. Lo anterior es muy probable que se deba a que son imágenes
1353 sin relación alguna entre ellas.

1354 El resto de los grupos, a excepción de Da Vinci y Monet, presentan desviaciones
1355 estándar superiores a 0.1, destacan **Van Gogh** y **Combinadas** con valores cercanos
1356 a 0.15. En el caso de **Da Vinci** y **Monet**, considerando los pequeños valores de
1357 desviación estándar que presentan, se puede afirmar que este descriptor es persistente
1358 en sus obras, es decir, el valor promedio de ASM en una pintura no varía mucho
1359 respecto a otra.

1360 La Figura 6.24 contiene los diagramas de cajas que fueron obtenidos para cada
1361 uno de los grupos estudiados. Este tipo de gráficas permite observar la dispersión
1362 de los datos obtenidos alrededor de la mediana.




Figura 6.24: Diagrama de cajas asociada al descriptor ASM.

1363 Correlación

1364 La correlación es un descriptor que ofrece valores altos para ventanas de tamaño
1365 reducido, su valor tiende a disminuir para ventanas de mayor tamaño. Es por la
1366 razón anterior, que los promedios para la mayoría de los pintores superan el **0.95** (ver
1367 cuadro 6.3). Sin embargo, en **Aleatorias** se observa el menor promedio correlación
1368 entre las imágenes que componen al grupo, seguido por **Combinadas**. Si se observa
1369 el cuadro de desviaciones estándar (Figura 6.4), se nota que la correlación es una
1370 característica que comparten la mayoría de los pintores, a excepción de **Picasso** y,
1371 los grupos **Aleatorias** y **Combinadas**.

1372 La Figura 6.25 muestra los diagramas de cajas asociado a los resultados obtenidos
1373 para cada pintura. En la Figura se observa que los grupos con mayor dispersión
1374 alrededor de la mediana son **Picasso**, **Aleatorias** y **Combinadas**.




Figura 6.25: Gráfica de cajas asociada al descriptor correlación.

1375 **Contraste**

1376 Dicho de manera sencilla, el contraste mide las diferencias de entre los píxeles de
1377 un vecindario. Mientras mayor sea la diferencia, mayor será el contraste.

1378 El cuadro 6.3 muestra a **Aleatorias** con el mayor promedio de contraste, seguido
1379 de **Van Gogh** y **Combinadas**. Sin embargo, no existen diferencias considerables
1380 respecto a los promedios más bajos (**Da Vinci** y **Dalí**). La tabla de desviaciones
1381 estándar tampoco muestra diferencias importantes, a excepción de **Aleatorias** que
1382 destaca sobre el resto.

1383 Cabe destacar que aunque los pintores comparten valores de desviación estándar
1384 similares, **Da Vinci** aparece nuevamente con el valor más pequeño.

1385 La Figura 6.26 muestra los diagramas de cajas obtenidos a partir de los prome-
1386 dios de cada pintura analizada. Se puede observar que **Aleatorias** tiene la mayor
1387 dispersión de datos alrededor de la mediana. Considerando solamente a los pintores,
1388 **Van Gogh** presenta los datos más dispersos, y **Da Vinci** aparece como el pintor
1389 con datos más concentrados alrededor de la mediana.




Figura 6.26: Diagrama de cajas asociada al descriptor contraste.

1390 Homogeneidad

1391 La homogeneidad incrementa su valor mientras menos contraste exista en el
 1392 vecindario analizado. En el cuadro 6.3 destaca sobre el resto **Dalí** y **Da Vinci**
 1393 con los promedios más altos. Al contrario, **Aleatorias** y sobretodo **Van Gogh**,
 1394 presentan los promedios más pequeños.

1395 Respecto a las desviaciones estándar (cuadro 6.4), **Da Vinci** aparece nuevamente
 1396 con el valor más pequeño, seguido por **Monet** y **Picasso**. Por otra parte, **Aleatorias**
 1397 aparece con el mayor valor, seguido de **Van Gogh**. Con los resultados expuestos, se
 1398 puede decir que la homogeneidad es otra característica persistente en los trabajos de
 1399 **Da Vinci**.

1400 La Figura 6.27 muestra los diagramas de cajas obtenidos a partir de los resultados
 1401 de homogeneidad para cada pintura. En estos diagramas se observa **Da Vinci** con
 1402 la menor dispersión de datos, seguido de **Monet**. Por otro lado, **Aleatorias** es el
 1403 grupo con mayor dispersión.




Figura 6.27: Diagrama de cajas asociado al descriptor homogeneidad.

1404 **Disimilitud**

1405 Es un descriptor similar al contraste, solo que en este caso se miden las diferencias
1406 absolutas de los valores de intensidad de los píxeles vecinos.

1407 El cuadro 6.3 muestra a **Van Gogh** con el promedio más alto, seguido de **Alea-**
1408 **torias**. Los promedios más pequeños aparecen en **Dalí** y **Da Vinci**.

1409 En el caso de las desviaciones estándar (cuadro 6.4) destaca **Aleatorias** con el
1410 valor más elevado. Por otra parte, **Da Vinci** aparece nuevamente con la desvia-
1411 ción estándar más baja, aunque no existen diferencias considerables con los valores
1412 presentados por el resto de los artistas.

1413 La Figura 6.28 muestra los diagramas de cajas asociados al descriptor *disimilitud*.
1414 Similar a lo mostrado en las desviaciones estándar, **Aleatorias** es el grupo con la
1415 mayor dispersión de datos. Los datos menos dispersos se presentan nuevamente en
1416 **Da Vinci** y también, en las pinturas de **Monet**.

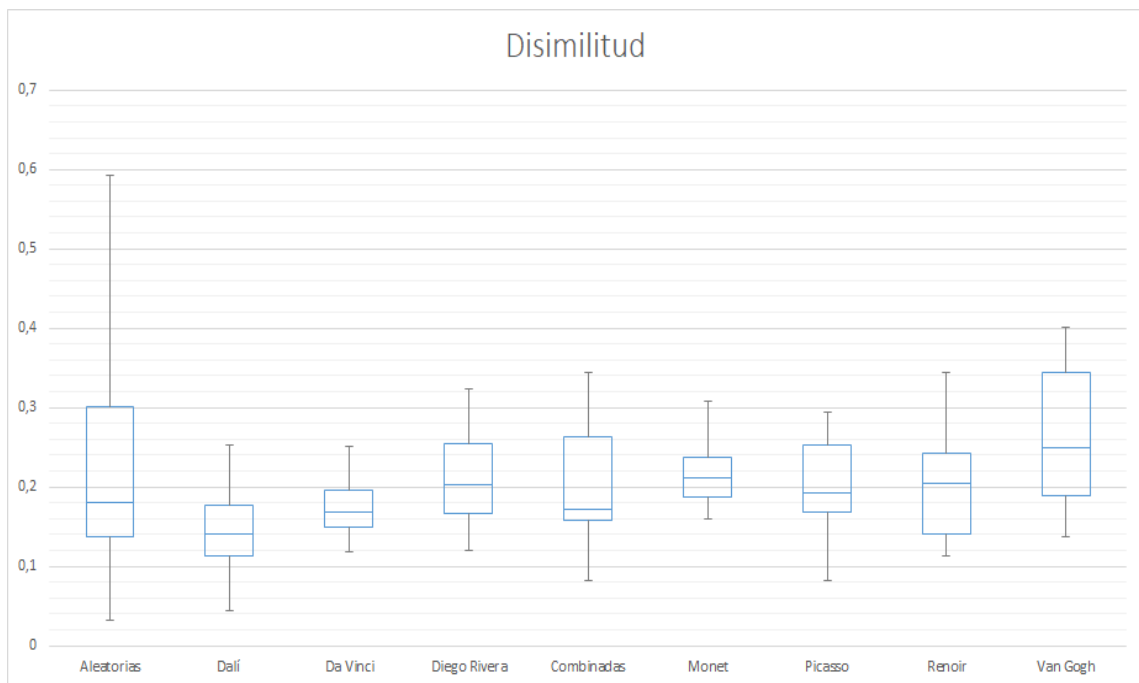


Figura 6.28: Diagrama de cajas asociada al descriptor disimilitud.

1417 Entropía

1418 La entropía es una medida de desorden de los píxeles. El mayor promedio se
 1419 observa en **Van Gogh** y **Aleatorias**. Los promedios más bajos los tienen **Dalí** y
 1420 **Da Vinci**, el resto de los grupos poseen promedios similares que oscilan entre 0.35
 1421 y 0.4.

1422 Se observa en el cuadro 6.4 donde aparecen las desviaciones estándar, que **Alea-**
 1423 **torias** aparece con el valor más alto, seguido de **Van Gogh**. **Monet** y **Da Vinci**
 1424 son los pintores con desviaciones más pequeñas, los cuales muestran diferencia con-
 1425 siderable con el resto de los artistas. Con lo anterior se puede afirmar que el índice
 1426 de entropía encontrado en pinturas tanto de **Da Vinci** como de **Monet** es poco
 1427 variable a lo largo de sus trabajos.

1428 La Figura 6.29 muestra los diagramas de cajas obtenidos de las pinturas analiza-
 1429 da. Como se pudo ver en el cuadro de desviaciones estándar, **Aleatorias** es el grupo
 1430 con mayor dispersión de datos, mientras que **Da Vinci** y **Monet** aparecen con la
 1431 menor dispersión de datos.

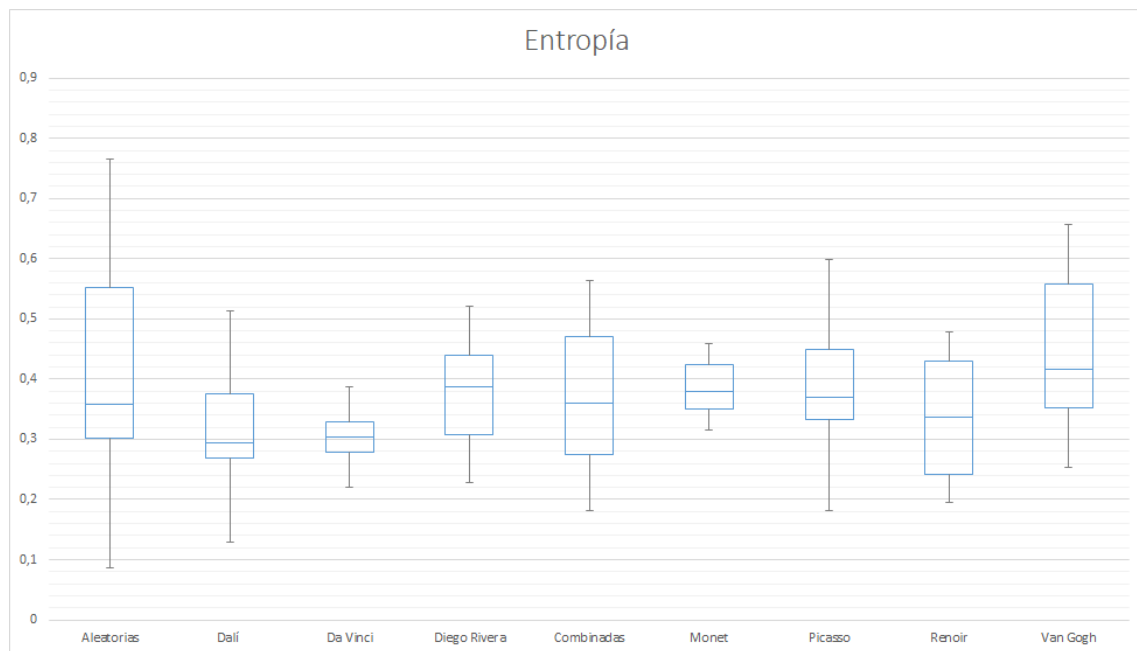


Figura 6.29: Diagrama de cajas asociada al descriptor entropía.

1432 6.2.2. Imágenes paramétricas

1433 Para decidir qué descriptores utilizar para crear las imágenes paramétricas se
 1434 realizó análisis de componentes principales a los seis descriptores calculados, consi-
 1435 derando solo los tres primeros componentes, con la meta de tratar de identificar a
 1436 aquellos descriptores menos correlacionados. Los vectores propios que resultaron de
 1437 este análisis se muestran en el apéndice D.

1438 De acuerdo a lo observado en los vectores propios, se concluyó que los descriptores
 1439 más correlacionados en el primero componente son **homogeneidad** y **correlación**.
 1440 En el segundo componente, la **entropía** fue el descriptor con mayor peso en la
 1441 mayoría de las pinturas; para el tercer componente, la **disimilitud** apareció con
 1442 mayor peso en la gran mayoría de las pinturas. Por lo expuesto anteriormente, se
 1443 eligieron dichos descriptores para generar imágenes paramétricas.

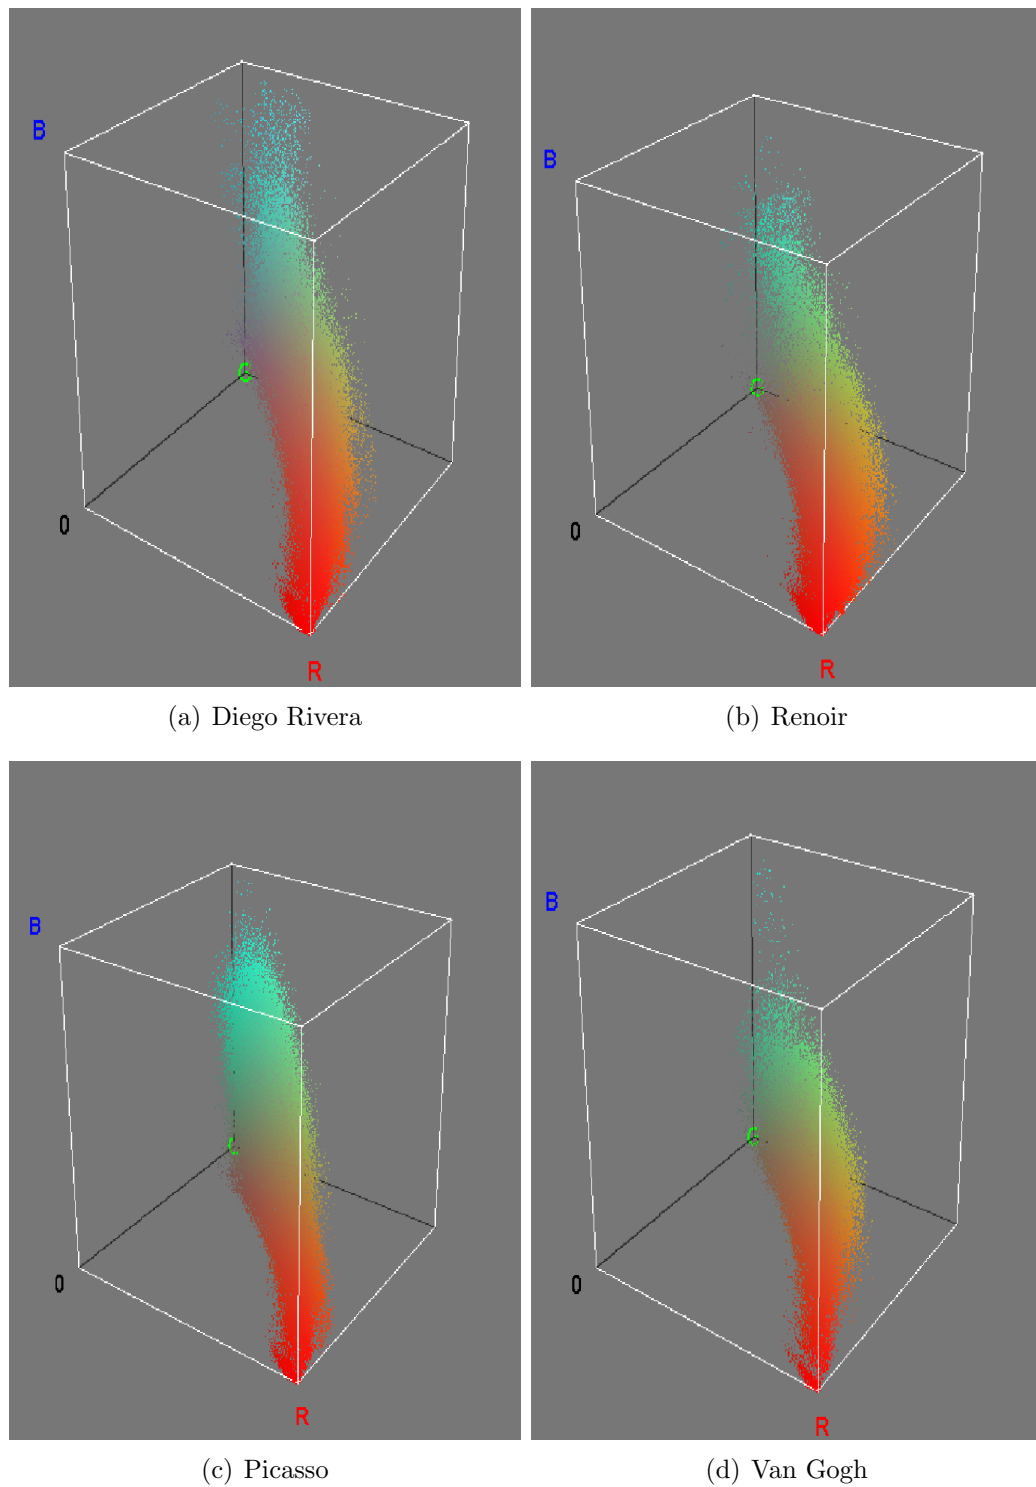


Figura 6.30: Distribuciones de imágenes paramétricas utilizando los descriptores disimilitud, homogeneidad y entropía.

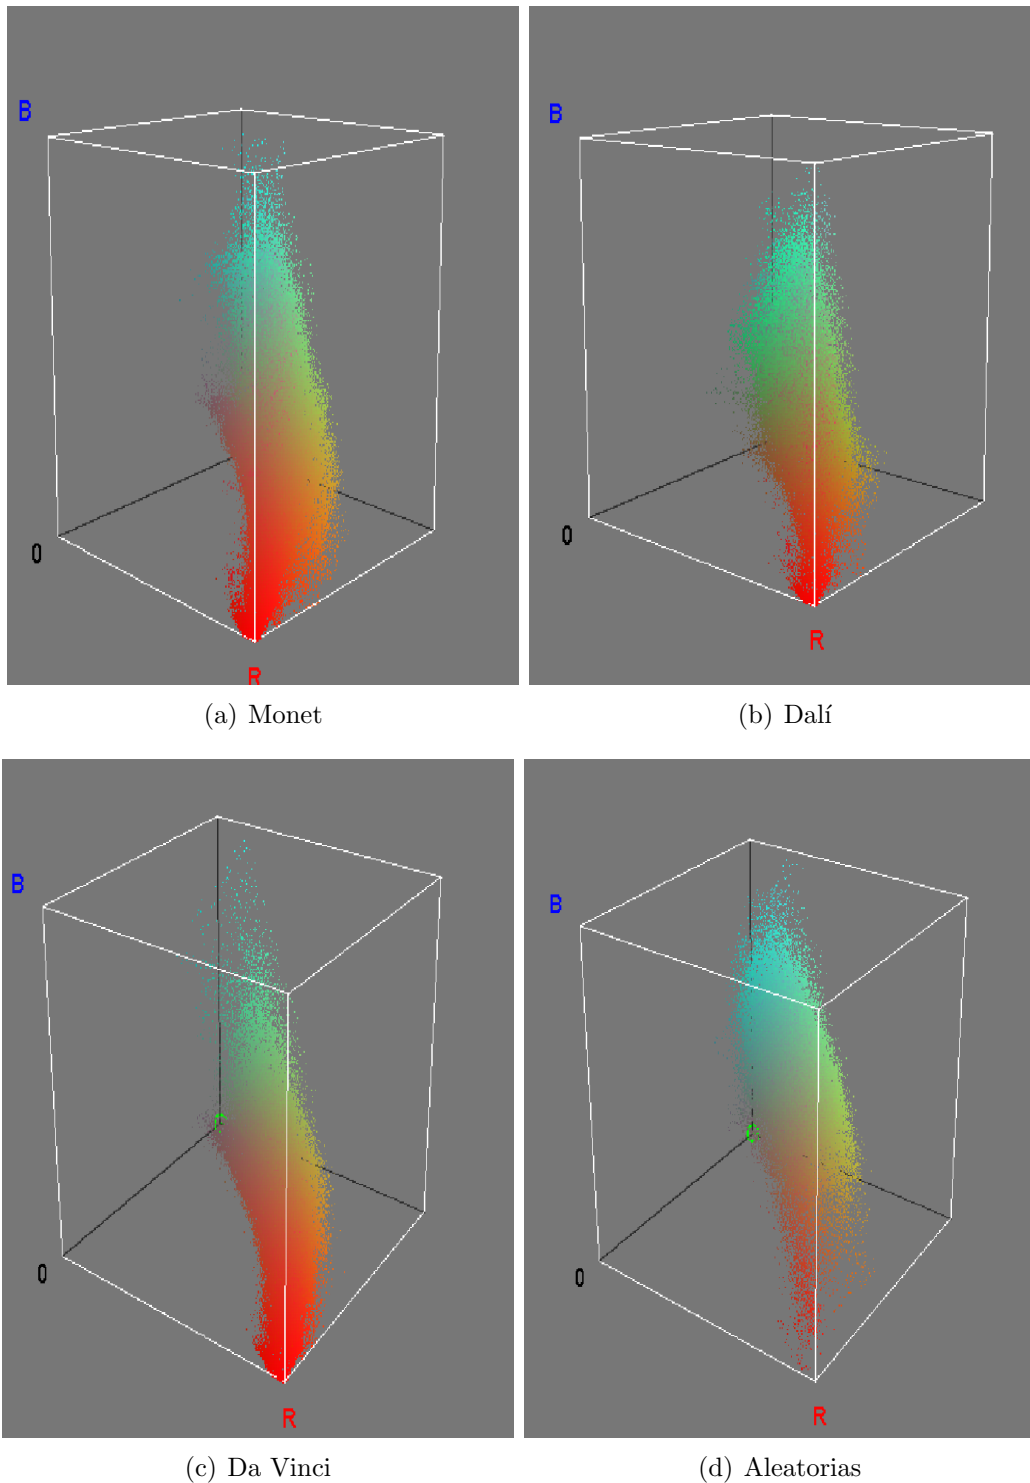


Figura 6.31: Distribuciones de imágenes paramétricas utilizando los descriptores disimilitud, homogeneidad y entropía.

1444 En las Figuras 6.30 y 6.31 se observa el comportamiento de la distribución formada por los descriptores disimilitud, entropía y homogeneidad. Se puede ver que
 1445 a pesar de que las pinturas pertenecen a distintos artistas, las distribuciones resultan bastante similares. No se logran detectar diferencias considerables entre los
 1446
 1447

1448 distintos pintores. Por esta razón, se decidió elegir dos combinaciones de descriptores
1449 adicionales: ASM, correlación, contraste y ASM, disimilitud y entropía.

1450 Las Figuras 6.32 y 6.33 muestran las distribuciones de la combinación ASM,
1451 correlación y contraste.

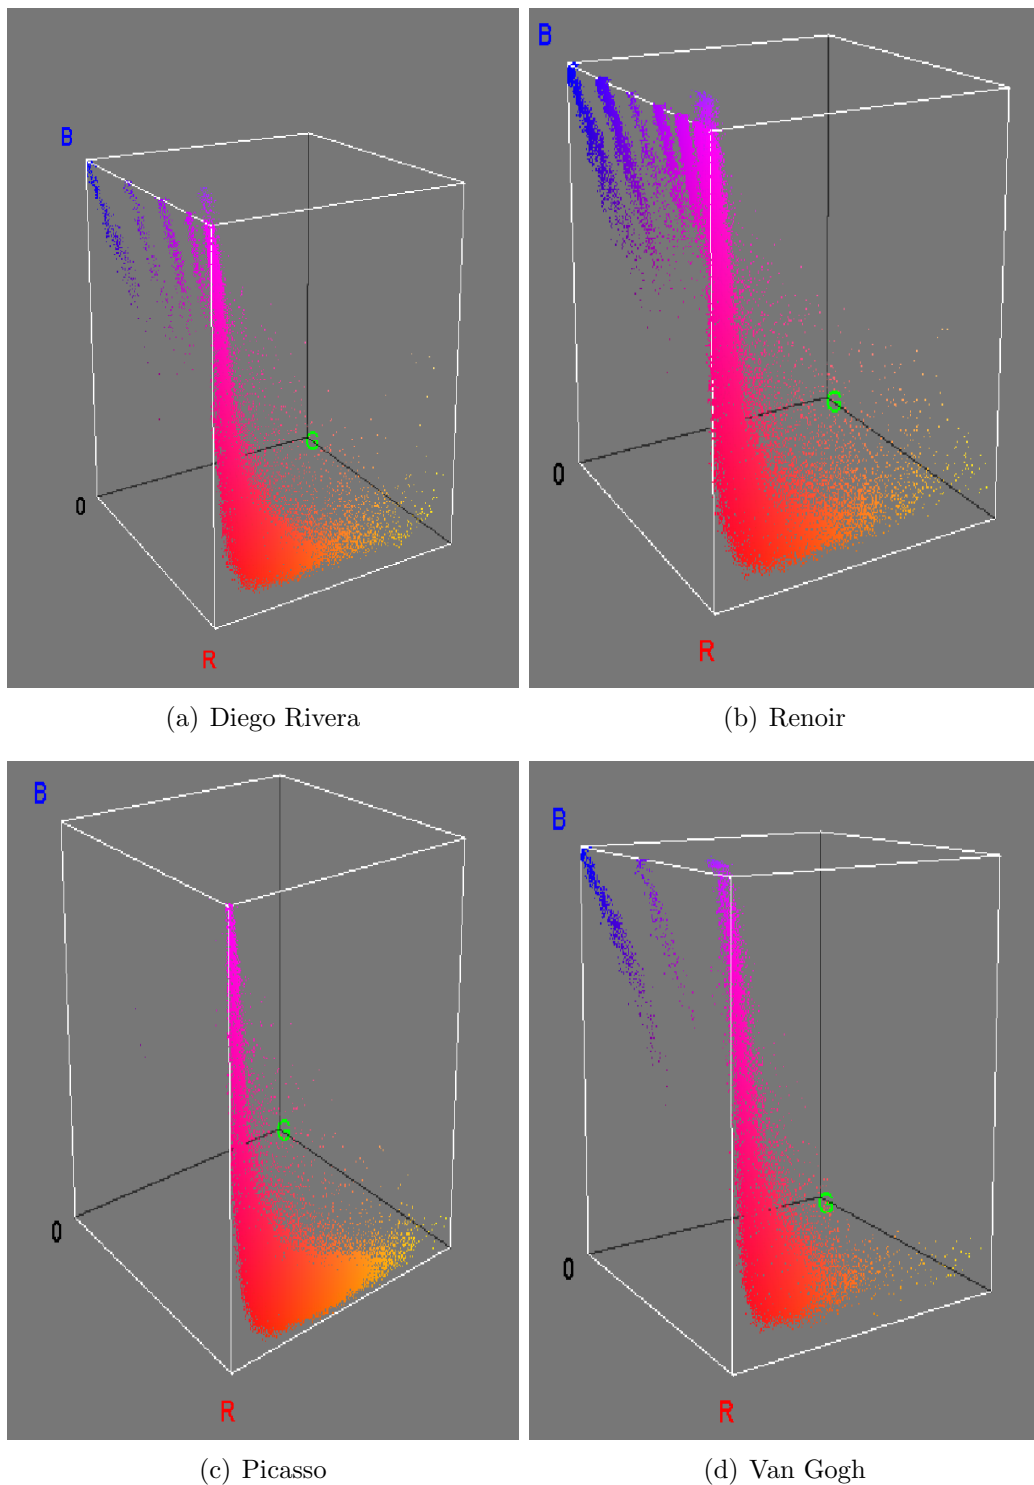


Figura 6.32: Distribuciones de imágenes paramétricas utilizando los descriptores ASM, correlación y contraste.

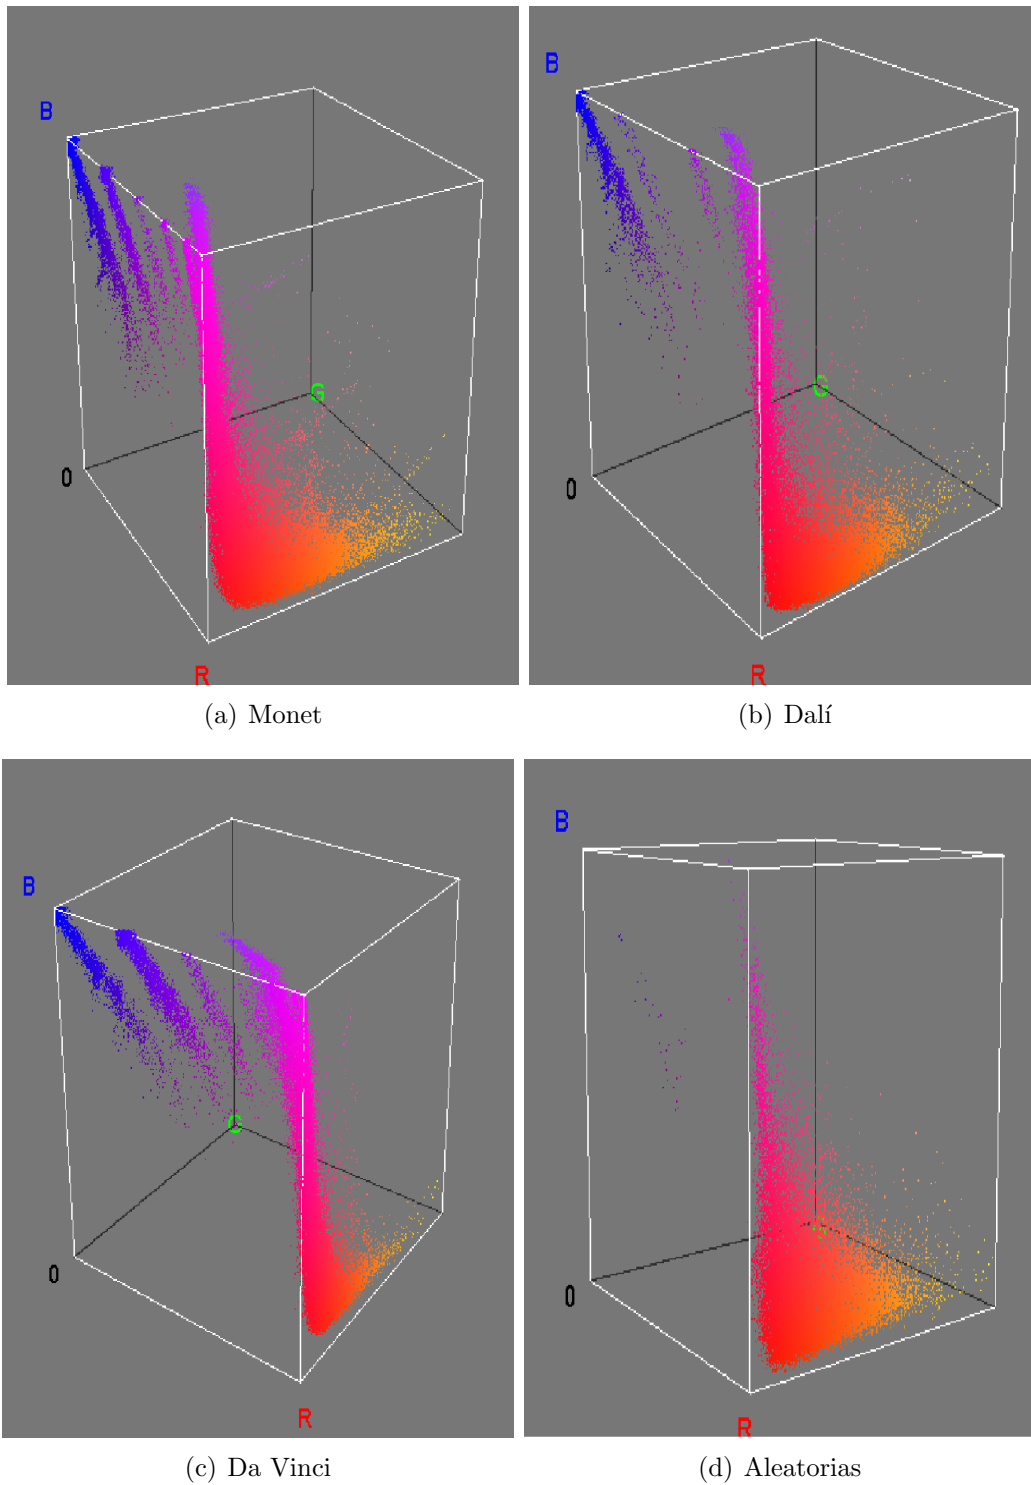


Figura 6.33: Distribuciones de imágenes paramétricas utilizando los descriptores ASM, correlación y contraste.

1452 Las Figuras 6.34 y 6.2.2 muestran las distribuciones de la combinación de des-
 1453 criptores ASM, disimilitud y entropía.

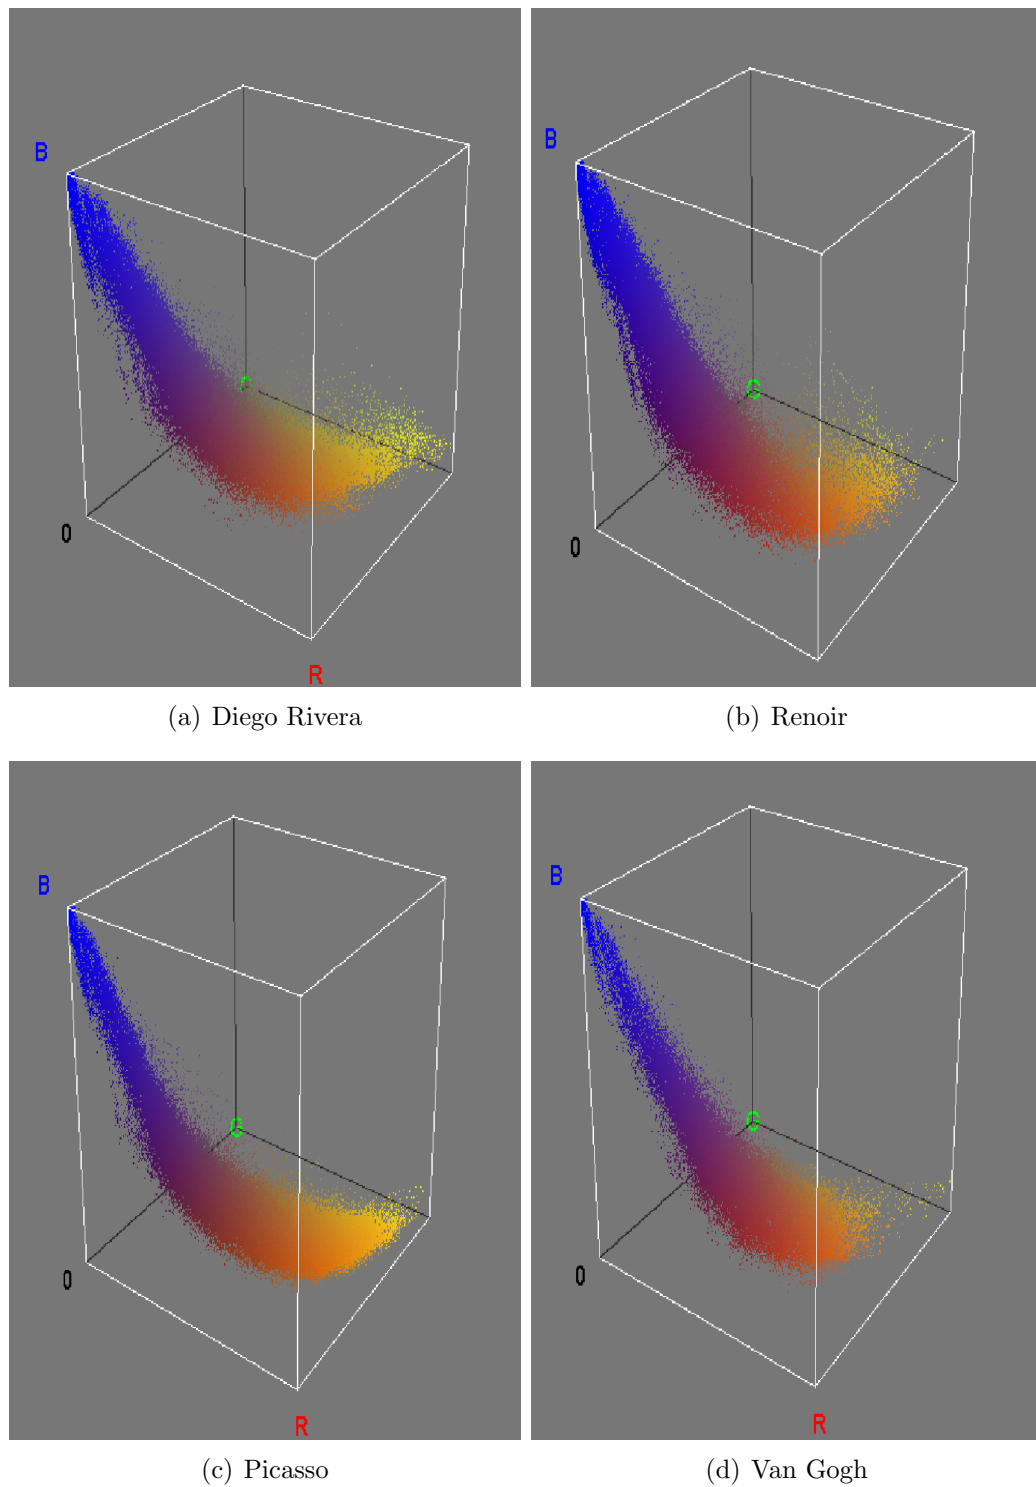


Figura 6.34: Distribuciones de imágenes paramétricas utilizando los descriptores ASM, disimilitud y entropía.

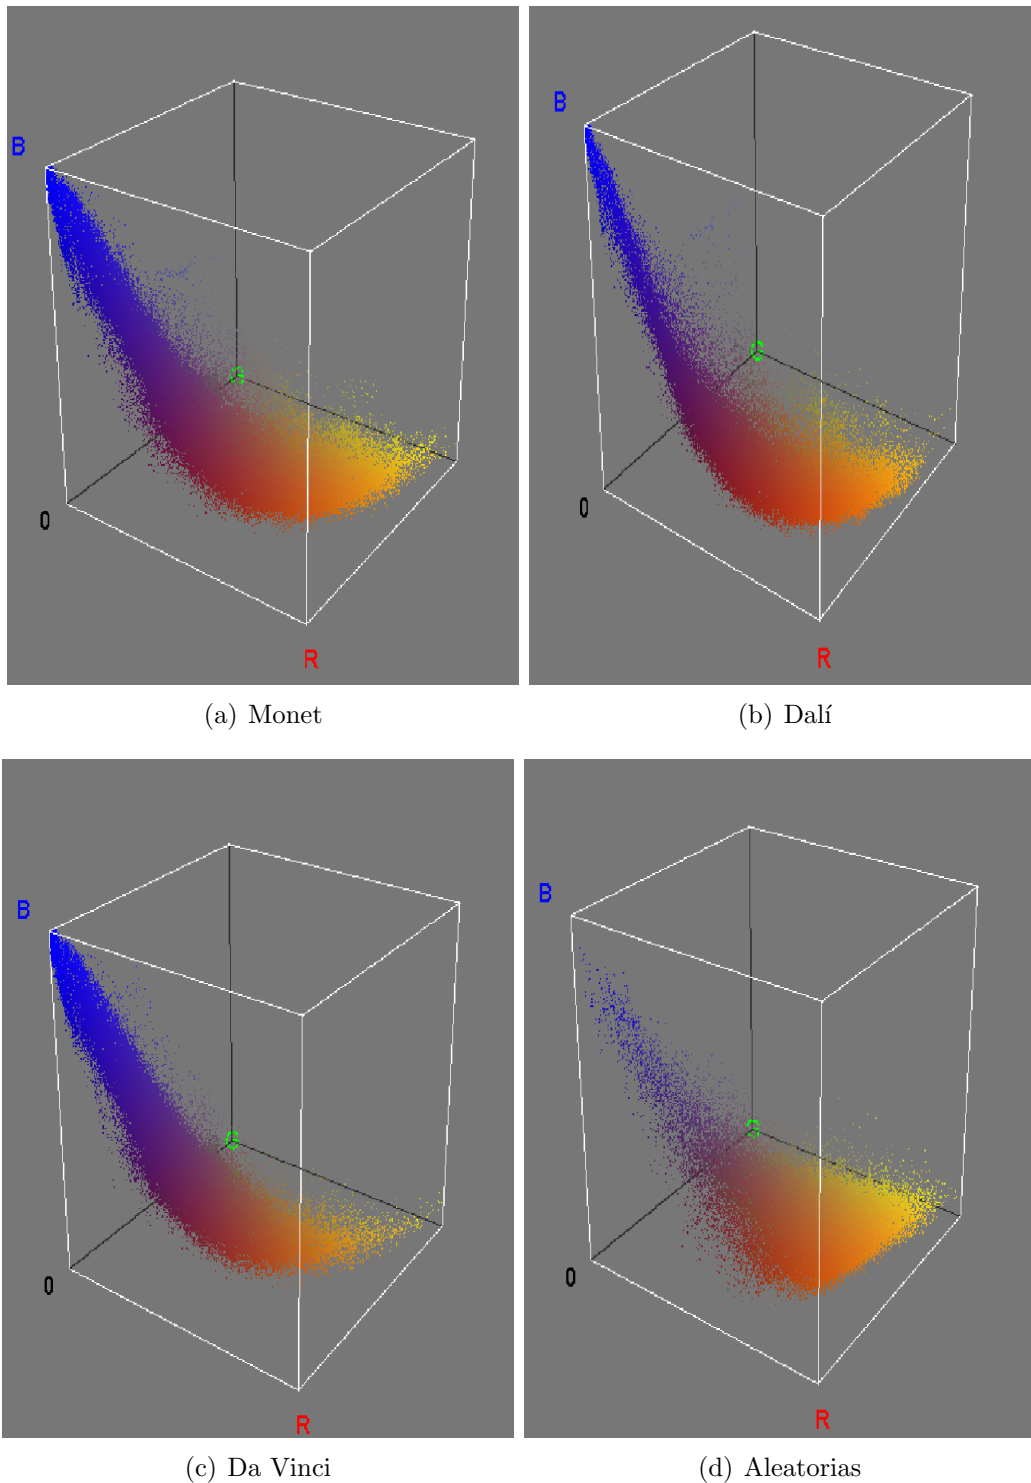


Figura 6.35: Distribuciones de imágenes paramétricas utilizando los descriptores ASM, disimilitud y entropía.

1454 Las distribuciones texturales de las dos nuevas combinaciones de descriptores
 1455 muestran comportamientos similares, a pesar de que se examinaron pinturas de
 1456 diferentes artistas. En algunas de las distribuciones se pueden observar ligeras dife-
 1457 rencias. Sin embargo, no se lograron detectar elementos o características específicos

1458 que permitan distinguir entre los diversos pintores estudiados.

1459 Estos resultados pueden deberse a los parámetros utilizados para calcular la
 1460 matriz de co-ocurrencia, podrían obtenerse resultados distintos si se aumenta el
 1461 tamaño deslizante y se realizan pruebas con distintas relaciones espaciales para el
 1462 calculo de la GLCM, además de probar con diferentes niveles de gris.

1463 6.2.3. Patrones binarios locales

Se utilizó radio=1 y se consideraron ocho vecinos para generar los histogramas de LBP y ULBP. Se compararon los histogramas, tanto de LBP como de ULBP de todas las pinturas pertenecientes al mismo artista. Cabe mencionar que mientras más pequeño sea el número arrojado tras la comparación más parecido existe entre los histogramas. Se promediaron los valores obtenidos después de aplicar la métrica de comparación y se calcularon las desviaciones estándar respectivas.

La métrica utilizada para comparar histogramas se conoce como **chi cuadrada** y se define como sigue:

$$d(H_1, H_2) = \sum_i^{\text{bins}} \frac{(H_{1i} - H_{2i})^2}{(H_{1i} + H_{2i})} \quad (6.1)$$

1464 El cuadro 6.5 muestra los datos obtenidos al calcular el promedio de las compara-
 1465 ciones y las desviaciones estándar. Las Figuras 6.36 y 6.37 muestran las gráficas de
 1466 los resultados de dichas comparaciones.

	Promedio ULBP	Desviación estándar	Promedio LBP	Desviación estándar
Aleatorias	0.413	0.3587	0.4528	0.391
Dalí	0.126373	0.20792	0.147291	0.132338
Da Vinci	0.063585	0.04012	0.0768	0.0466
Diego Ri- vera	0.0829	0.107057	0.122103	0.0881514
Diversas	0.1801	0.19124	0.20132	0.189276
Monet	0.106047	0.0996505	0.133392	0.118267
Picasso	0.0740757	0.065366	0.10156	0.0844885
Renoir	0.124663	0.166157	0.138824	0.166985
Van Gogh	0.1161112	0.0925035	0.131	0.098104

Cuadro 6.5: Valor promedio de las comparaciones entre histogramas de un mismo pintor y desviaciones estándar respectivas.




Figura 6.36: Gráfica que muestra los valores promedio al comparar histogramas utilizando ULBP y desviaciones estándar de la comparación.




Figura 6.37: Gráfica que muestra los valores promedio al comparar histogramas utilizando ULBP y desviaciones estándar de la comparación.

1467 En la gráfica se puede observar que las comparaciones entre los histogramas de
 1468 los grupos control, **Aleatorias** y **Combinadas** muestran que las imágenes perte-
 1469 necientes a esos grupos tienen histogramas de **LBP** bastante diferentes entre ellas,

1470 sobre todo en el grupo Aleatorias. De acuerdo a la gráfica, **Da Vinci** y **Picasso** son
 1471 los que tienen pinturas que generan los histogramas de **LBP** más parecidos entre
 1472 ellos. Sin embargo, el resto de los pintores tampoco presentan muchas diferencias
 1473 entre los histogramas de **LBP** asociados a sus pinturas.

1474 De la misma forma que en secciones anteriores, se utiliza la desviación estándar
 1475 de cada promedio calculado para observar las variaciones que existen de pintura a
 1476 pintura de cada pintor estudiado. En las gráficas presentadas en la Figura ?? se
 1477 observa que es **Da Vinci** es quien presenta los histogramas más parecidos, tomando
 1478 como referencia los valores de desviación estándar. A excepción de **Monet** y **Dalí**,
 1479 que presentan variaciones más significativas, el resto de los pintores analizados tie-
 1480 ne valores de desviación estándar pequeños, comparados con los grupos control ya
 1481 mencionados.

1482 6.2.4. Patrones binarios locales dominantes

1483 El cuadro 6.6 muestra el número de **DLBP** promedio para cada pintor, así como
 1484 las desviaciones estándar asociadas.

1485 Se observa que **Aleatorias** es el grupo que presenta la menor cantidad de patrones
 1486 dominantes. Esto puede deberse a que las imágenes que integran al grupo no son
 1487 pinturas y pueden resultar menos complejas, a nivel de texturas.

1488 El resto de los grupos contienen solo imágenes de pinturas, muestran en promedio
 1489 60 patrones dominantes. Destacan sobre el resto **Picasso** y **Van Gogh** quienes
 1490 presentan en promedio, 84 y 73 patrones dominantes respectivamente. La gráfica de
 1491 desviaciones estándar (Figura 6.38) muestra que **Da Vinci** es el pintor con menor
 1492 variabilidad de patrones, lo que quiere decir que suele mantener un estilo similar en
 1493 cada una de sus obras.

	Patrones promedio	Desviación estándar
Aleatorias	51.2727	29.4868
Dalí	63.6818	20.9054
Da Vinci	62.0833	14.2036
Diego Rivera	63.2143	20.8196
Diversas	68.2857	21.7303
Monet	66.9091	19.2889
Picasso	83.5	20.4267
Renoir	62.35	18.87
Van Gogh	74.0625	18.2053

Cuadro 6.6: Número de patrones dominantes promedio y desviaciones estándar

1494 La Figura 6.38 muestra los diagramas de caja obtenidos a partir de los patrones
 1495 dominantes de cada pintura que fue analizada. Como en la mayoría de los resultados
 1496 obtenidos, se observa que los pintores que mostraron los datos menos dispersos son
 1497 **Da Vinci** y **Monet**




Figura 6.38: Diagrama de cajas asociado al número de patrones dominantes obtenidos para cada pintura analizada.

1498

Capítulo 7

1499

conclusiones

1500

1501

1502

1503

En este trabajo se presentó el análisis de la distribución de color en el espacio **RGB** y el análisis textural de pinturas pertenecientes a diversos artistas. El objetivo del análisis, fue tratar de caracterizar el estilo de cada uno de estos pintores utilizando a través del uso de técnicas y herramientas para el análisis de color y textura.

1504

1505

1506

1507

1508

1509

1510

1511

1512

1513

1514

En el apartado de análisis de color no se lograron identificar características únicas que ayuden a distinguir a todos los pintores estudiados, algunos de ellos presentaron valores muy parecidos en los descriptores utilizados para tratar de caracterizarlos. Sin embargo, los resultados obtenidos, mostraron que hay algunos pintores que sí muestran diferencias importantes respecto al resto. Por ejemplo, **Pablo Picasso** presenta el mayor promedio de dimensión fractal y **Da vinci** el menor promedio, ambos con poca variación de la misma a lo largo de su trabajo. Con lo establecido anteriormente, se puede decir que es probable que las obras de **Picasso** presenten valores similares (cerca de 2.4) de dimensión fractal entre ellas. De la misma manera, es probable encontrar valores similares (cerca de 2.2) al estudiar la dimensión fractal en las obras de **Da Vinci**.

1515

1516

1517

1518

1519

Un caso bastante interesante fue **Van Gogh**, quien siempre mostró los valores más altos de desviación estándar en la mayoría de las características revisadas, y también, los histogramas más desordenados. Lo anterior caracteriza su obra como poco predecible y muy cambiante de una pintura a otra, al menos en características y elección de color.

1520

1521

1522

1523

1524

1525

El grupo **Aleatorias**, que está conformado por imágenes que no tienen relación entre ellas, y **Combinadas**, que está compuesto por pinturas de los diversos pintores estudiados, mostraron diferencias considerables con el resto de los grupos compuestos solamente por las pinturas de cada artista. Mostraron también, grandes variaciones en las características promedio que les fueron calculadas, por lo que se concluye que la mayoría del trabajo de los pintores preserva cierta relación.

1526

1527

1528

1529

1530

El mapa de color que se calculó a las superficies generadas a partir de la distribución de color permitió visualizar qué tan bien se ajusta el modelo del elipsoide a la distribución de color. Para cuantificar dicho ajuste, se utilizó el RSME (root-squared mean error). Casi todos los pintores mostraron promedios de ajuste similares. En este rubro destacó nuevamente **Van Gogh** con el peor ajuste.

1531

1532

En el caso del análisis textural se trató de caracterizar a los pintores utilizando descriptores obtenidos de la matriz de co-ocurrencia de niveles de gris. Se pro-

1533 baron tres diferentes relaciones espaciales para el cálculo de la misma, pero no se
1534 encontraron diferencias significativas. En el caso de la **correlación**, todos los gru-
1535 pos obtuvieron promedios bastante altos, sin embargo, esto se debió al tamaño de la
1536 ventana utilizada para calcular las imágenes basadas en la textura. En el **contraste**
1537 también se observaron promedios similares entre los distintos pintores.

1538 Similar a como ocurrió en el análisis de color, **Da Vinci** apareció en con los va-
1539 lores más pequeños de desviación estándar y destacó en descriptores como segundo
1540 momento angular y homogeneidad. Al contrario, **Van Gogh** se mostró nuevamen-
1541 te, muy difícil de caracterizar, apareciendo con los mayores valores de desviación
1542 estándar y los promedios más bajos de homogeneidad así como los mas altos de
1543 entropía y disimilitud.

1544 El comportamiento mostrado por **Da Vinci**, tanto en el caso de análisis de color
1545 como en el de textura, es probable que se deba a el uso de técnicas como el *esfumado*
1546 y *claroscuro* que le daban ese estilo tan particular, además de que la mayoría de las
1547 pinturas que se revisaron son de Figuras humanas.

1548 Los resultados obtenidos a partir de las imágenes paramétricas no fueron satisfac-
1549 torios, ya que no se lograron detectar diferencias entre las distribuciones texturales
1550 de las diferentes combinaciones que se realizaron, a pesar, de que se trató de elegir
1551 a los descriptores con menor correlación entre ellos, para formar las imágenes. Es
1552 probable que si se cambia el tamaño de la ventana deslizante y los niveles de gris
1553 utilizados para calcular la GLCM puedan obtenerse resultados distintos.

1554 Los histogramas de **LBP** y **ULBP**, sí mostraron diferencias entre los diversos
1555 pintores. Se observa en los grupos control, **Aleatorias** y **Combinadas**, que la dis-
1556 tancia entre histogramas es bastante amplia, mientras que en los grupos de pintores,
1557 la distancia entre histogramas se reduce considerablemente. Para este descriptor, se
1558 observa que existe sí relación entre las pinturas pertenecientes a un solo artista, por
1559 lo que este tipo de métricas se podrían utilizar para reconocimiento o clasificación .
1560 Por último, en el caso de los **DLBP** se encontró que las imágenes que no son pintu-
1561 ras, parecen ser menos complejas que las pinturas, ya que fueron el grupo que menos
1562 patrones dominantes requirió para representar a sus imágenes. Destacaron sobre el
1563 resto **Picasso** y **Van Gogh**, ya que fueron los pintores que presentan mayor número
1564 de patrones, en promedio, a lo largo de sus obras.

1565 7.1. Trabajo a futuro

1566 Sería interesante observar las características de los pintores estudiados en otros
1567 espacios de color, los cuales podrían revelar información significativa para caracte-
1568 rizar a cada artista. Además, utilizar los datos obtenidos para realizar un análisis
1569 estadístico comparativo, y también, probar las herramientas desarrolladas con copias
1570 no auténticas.

1571 Un tema que quedo pendiente por explorar es el análisis de forma y contornos
1572 de las pinturas, de dicho análisis se podrían extraer otro tipo de descriptores que
1573 ayuden a la caracterizar los trabajos de los pintores.

1574 Parece pertinente profundizar el análisis textural, estudiando los descriptores
1575 de la matriz de co-ocurrencia como las imágenes paramétricas utilizando diferentes

1576 distribuciones espaciales para calcular la matriz, así como diferentes tamaños de
1577 ventanas deslizantes para generar las imágenes basadas en los descriptores y distintos
1578 niveles de gris.

1579 Otro tema por explorar sería la inclusión de herramientas de inteligencia artificial,
1580 como los clasificadores, que reciban como parámetros de entrada los valores de los
1581 descriptores obtenidos en este trabajo y observar si son capaces de clasificar de
1582 manera correcta las pinturas por autor.

1583 Por último, en lugar de estudiar a autores de forma individual, sería interesante
1584 agrupar pinturas por periodo o corriente artística y caracterizar cada uno de ellos.

1585 Apéndice A

1586 En este capítulo se explora de manera breve la vida y obra de cada uno de los
1587 pintores estudiados. Asimismo, se presentan las características de los movimientos
1588 artísticos a los cuales pertenecieron, con la finalidad de tener mejor entendimiento
1589 de sus obras y de acuerdo al contexto histórico y cultural en el que fueron creadas.

1590 A.1. Movimientos artísticos

1591 Un movimiento artístico es un conjunto de títulos que se otorgan a obras de arte
1592 que comparten los mismos ideales artísticos, estilo, técnicas o marco temporal (*what*
1593 *is an art movement?*, n.d.).

1594 No existe una regla que determina qué constituye un movimiento artístico. Los
1595 movimientos permiten agrupar artistas de cierto periodo o estilo para que puedan
1596 ser estudiados dentro del contexto adecuado (*what is an art movement?*, n.d.).

1597 A.1.1. Renacimiento (1400-1600)

1598 El *Renacimiento* se refiere a un periodo de la historia en Europa, entre los años
1599 1400 y 1600. El *Renacimiento* se asocia principalmente con Italia, donde comenzó
1600 en el siglo XIV, aunque países como Alemania, Inglaterra y Francia atravesaron por
1601 los mismos cambios culturales (Szalay, 2016).

1602 Los pensadores del *Renacimiento* consideraban que el periodo del Medioevo había
1603 sido un declive cultural. Por esta razón, el *Renacimiento* se caracterizó por un re-
1604 novado interés en las antigüedades clásicas. Ellos buscaban revitalizar su cultura a
1605 través de re-enfatizar filosofías y textos clásicos (Szalay, 2016).

1606 Algunos de los mayores descubrimientos que ocurrieron durante el *Renacimiento*
1607 están relacionados con astronomía, filosofía, la imprenta, técnicas de pintura y escul-
1608 tura, la exploración del mundo, y finalmente, en el *Renacimiento* tardío, los trabajos
1609 de Shakespeare. Fue durante el *Renacimiento*, que el matemático y astrónomo pola-
1610 co **Nicolás Copérnico** publicó, en la década de 1530, la teoría de un sistema solar
1611 heliocéntrico.

1612 **Galileo Galilei** fue también, una de las grandes mentes del *Renacimiento*, aun-
1613 que fue perseguido por la iglesia debido a sus experimentos. Galileo mejoró la idea del
1614 telescopio, descubrió nuevos cuerpos celestiales y fundamentó la teoría de Copérnico
1615 con sus descubrimientos.

1616 Alto renacimiento (1490-1527)

1617 El *alto Renacimiento* gira en torno a tres Figuras fundamentales: **Leonardo**
 1618 **Da Vinci**, **Miguel Ángel** y **Rafael**. Cada uno de ellos representó un importante
 1619 aspecto del periodo: Leonardo fue la representación perfecta del hombre renacen-
 1620 tista; Miguel Ángel, emanaba poder creativo; Rafael creó trabajos que expresaban
 1621 perfectamente el espíritu clásico (*Renaissance*, n.d.).

1622 Arte Renacentista

1623 El arte renacentista estuvo fuertemente influenciado por el arte clásico. Los ar-
 1624 tistas buscaron inspiración en la escultura griega y romana, así como en la pintura
 1625 y artes decorativas (Szalay, 2016). Tanto el arte clásico como el arte renacentista se
 1626 inspiraron en la belleza humana y la naturaleza.

1627 El arte renacentista fue considerado un medio para explorar la naturaleza, así
 1628 como un registro de descubrimientos. Estaba basado en la observación y se practicaba
 1629 de acuerdo a principios matemáticos de balance, armonía, y perspectiva, que se
 1630 desarrollaron durante ese tiempo .

1631 Características de la pintura renacentista

1632 En las pinturas renacentistas se pueden observar las siguientes características
 1633 (McKay and McKay, 2010) :

1634 **Perspectiva:** Agrega un aspecto tridimensional a las pinturas. Los artistas del *Re-*
 1635 *nacimiento* re-descubrieron y expandieron las ideas sobre perspectiva lineal,
 1636 línea de horizonte, y punto de fuga.

1637 **Perspectiva lineal:** Una pintura con perspectiva lineal es como mirar a través
 1638 de una pintura y pintar exactamente lo que se ve en la ventana. Los
 1639 objetos más lejanos se dibujan más pequeños, mientras que los objetos
 1640 cercanos aparecen de mayor tamaño.

1641 **Línea de horizonte:** Se refiere al punto en la distancia donde los objetos se
 1642 vuelven infinitamente pequeños, que quedan reducidos al tamaño de una
 1643 línea.

1644 **Punto de fuga:** Es el punto, muy lejano, en el que las líneas paralelas parecen
 1645 converger, frecuentemente sobre la línea de horizonte.

1646 **Realismo y naturalismo:** Los objetos, especialmente las personas, lucían más
 1647 reales. Los artistas del *Renacimiento* estudiaron anatomía, midieron propor-
 1648 ciones, en búsqueda del la forma humana ideal.

1649 A.1.2. Surrealismo (1924-1966)

1650 Floreció en Europa entre la primera y segunda guerra mundial. El movimiento
 1651 representaba una reacción en contra de la destrucción forjada por el *racionalismo*
 1652 que había guiado a la cultura Europea en el pasado y, que había culminado en
 1653 los horrores de la primera guerra mundial (?). Los surrealistas creían que el arte

1654 era creado en la mente inconsciente. Muchos artistas trabajan con técnicas visua-
1655 les fantásticas y técnicas psicológicas, basaban su arte en memorias, sentimientos
1656 y, sueños. Usualmente utilizaban hipnotismo y drogas para aventurarse al mundo
1657 onírico, donde buscaban imágenes del inconsciente (Moffat, 2011).

1658 Los artistas del surrealismo adoptaron las ideas de **Sigmund Freud**, quién ins-
1659 piró a muchos de ellos. Sin embargo, surgieron dos interpretaciones de dichas ideas:
1660 el surrealista automático y el surrealista verístico. Los automáticos o automatistas,
1661 creían que el arte abstracto, era la única forma de llevar imágenes del subconsciente
1662 aunque estas no debían ser interpretadas. Por otro lado, los verísticos, creían que las
1663 imágenes del subconsciente sí tenían un significado (Moffat, 2011).

1664 **Características del arte surrealista**

1665 El *Surrealismo* tomó elementos del *cubismo* y del *expresionismo* además de al-
1666 gunas técnicas del *dadaísmo*.

1667 Algunos elementos característicos del *surrealismo* incluyen: levitación, cambios
1668 de escala en los objetos, transparencia, y repetición (Moffat, 2011). La yuxtaposición
1669 es otra característica, donde se encuentran elementos que rara vez aparecerían juntos
1670 en una situación típica. Por ejemplo, una sombrilla y una máquina de coser sobre
1671 una mesa para disección. La yuxtaposición se usaba para mostrar una metáfora o
1672 expresar cierto mensaje.

1673 A pesar de que las pinturas son los elementos más representativos del movimiento,
1674 también son los más complicados de clasificar, ya que cada artista recurría a sus
1675 propias motivaciones, presentes en sus sueños o mente inconsciente. En su forma más
1676 básica, las imágenes surrealistas son extravagantes, confusas, e incluso, misteriosas.
1677 Sin embargo, la naturaleza es uno de los temas más recurrentes. Por ejemplo, los
1678 trabajos de **Salvador Dalí** frecuentemente incluyen hormigas o huevos (*Surrealism*,
1679 n.d.).

1680 **A.1.3. Cubismo (1907-1922)**

1681 Desarrollado por **Pablo Picasso** y **George Braques** alrededor de 1907 en la
1682 ciudad de París. Fue le primer estilo de arte abstracto que evolucionó a principios
1683 del siglo XX en repuesta a un mundo que cambiaba a una velocidad sin preceden-
1684 tes. Los cubistas retaron las formas convencionales de representación, tales como la
1685 perspectiva, que había sido la regla desde el *Renacimiento*. Su objetivo principal era
1686 desarrollar una nueva forma de ver lo que el mundo moderno reflejaba (*Cubism -*
1687 *The First Style of Abstract Art*, n.d.).

1688 Un pintura cubista típica muestra personas, lugares u objetos reales, pero no
1689 desde un punto de vista fijo. En cambio, mostraban muchas partes de un sujeto u
1690 objeto a la vez; visto desde diferentes ángulos, y reconstruido en una composición
1691 de planos, formas y colores.

1692 **Cubismo analítico (1907-1912)**

1693 El *Cubismo* presentó dos fases, una de ellas fue el *Cubismo analítico*. Aquí, los
1694 artistas analizaban a los objetos desde muchos puntos de vista y eran reconstruidos

1695 dentro de un marco geométrico. La **paleta de colores** se limita a tonos terrosos y
1696 grises apagados.

1697 **Cubismo sintético 1912-1922**

1698 La otra fase, que inició alrededor de 1912 fue el *cubismo sintético*. Este fue un
1699 intento para revitalizar el estilo del *cubismo* y rescatarlo de la abstracción total.
1700 A diferencia del las superficies monocromáticas del *cubismo analítico*, el *cubismo*
1701 *sintético* introdujo un estilo más decorativo y colorido.

1702 **Características de la pintura cubista (*Cubism*, n.d.)**

- 1703 ■ Los artistas abandonaron la idea de un punto de vista fijo, en su lugar, utiliza-
1704 ban múltiples puntos de vista. De esta manera diferentes vistas de un objeto
1705 se mostraban en la misma pintura.
- 1706 ■ El estilo cubista se concentraba en imágenes de dos dimensiones. Rechazaba
1707 técnicas como la perspectiva lineal, el claroscuro y la idea tradicional de imitar
1708 la naturaleza .

1709 **A.1.4. Impresionismo**

1710 Movimiento que surge a finales del Siglo XIX en Francia. El término fue utilizado
1711 por primera vez en 1874. Fue usado con sentido irónico para describir las obras de
1712 una nueva generación de pintores como **Monet, Renoir, Pissarro y Degas**.

1713 **Características de la pintura impresionista (*Impresionismo*, n.d.)**

1714 **Paisaje como tema principal:** El paisaje ofrece elementos que los impresionistas
1715 buscan plasmar en sus cuadros: el aire libre, contacto con la naturaleza, los
1716 efectos de la luz.

1717 **Técnica:** Los impresionistas se caracterizan por una técnica rápida y pinceladas
1718 largas.

1719 **Color:** Eliminan el color negro de su paleta de colores. Lo anterior se debe a que los
1720 pintores nunca observan sombras totalmente negras, sino coloreadas. El blanco
1721 puro tampoco existe, sino que la luz está cargada de matices. Apuestan por
1722 colores puros.

1723 **Perspectiva** Desaparece el punto de fuga. Se inclinan por una pintura plana y
1724 bi-dimensional.

Apéndice B

1726 En este apéndice se presentan algunas propiedades útiles de la media y desviación
1727 estándar así como el procedimiento seguido para modificarlas.

1728 Propiedades de la media de un conjunto de datos

Multiplicación por un escalar Sea \bar{X} la media de un conjunto ω de datos cualquiera y definida como se mostró en la ecuación 3.5.

Si se multiplica a cada $x_i \in \omega$ por un escalar f , la media \bar{X}_f del conjunto $\omega' = f\omega$ queda definida de la siguiente manera:

$$\bar{X}_f = \sum_{i=0}^N \frac{fx_i}{N} = f \sum_{i=0}^N \frac{x_i}{N} \quad (\text{B.1})$$

pero $\bar{X} = \sum_{i=1}^N \frac{x_i}{N}$ entonces:

$$\bar{X}_f = f\bar{X} \quad (\text{B.2})$$

1729 De la ecuación B.2 se puede concluir que al multiplicar un conjunto de datos ω por
1730 un escalar f cualquiera, la media \bar{X}_f del nuevo conjunto ω' es igual a la media \bar{X}
1731 del conjunto ω multiplicada por dicho escalar.

1732 **Adición de una constante** Sea \bar{X} la media de un conjunto ω de datos cualquiera
1733 y definida como en la ecuación 3.5.

1734 Si se suma a cada $x_i \in \omega$ una constante C , la media \bar{X}_c del conjunto $\omega' = \omega + C$
1735 queda definida de la siguiente manera:

$$\bar{X}_c = \sum_{i=1}^N \frac{x_i + C}{N} \quad (\text{B.3})$$

$$\bar{X}_c = \frac{\sum_{i=1}^N x_i + \sum_{i=1}^N C}{N} \quad (\text{B.4})$$

$$\bar{X}_c = \frac{\sum_{i=1}^N x_i}{N} + \frac{NC}{N} \quad (\text{B.5})$$

$$\bar{X}_c = \frac{\sum_{i=1}^N x_i}{N} + C \quad (\text{B.6})$$

pero $\bar{X} = \sum_{i=1}^N \frac{x_i}{N}$ entonces:

$$\bar{X}_c = \bar{X} + C \quad (\text{B.7})$$

1736 De la ecuación B.7 se puede concluir que al sumar una constante C cualquiera a un
1737 conjunto de datos ω , la media \bar{X}_c del nuevo conjunto ω' es igual a la media \bar{X} del
1738 conjunto ω más dicha constante.

1739

1740

1741 Propiedades de la desviación estándar de un conjunto de datos

Multiplicación por un escalar Sea σ la desviación estándar de un conjunto de datos ω cualquiera definida como en la ecuación 3.7.

Si se multiplica a cada $x_i \in \omega$ por un escalar f cualquiera, la desviación estándar σ_f del nuevo conjunto de datos $\omega' = f\omega$ se define como:

$$\sigma_f = \sqrt{\sum_{i=1}^N \frac{(fx_i - f\bar{X})^2}{N}} \quad (\text{B.8})$$

De la ecuación B.2 se sabe que la media de ω' es igual a la media de ω por el escalar f .

$$\sigma_f = \sqrt{\sum_{i=1}^N \frac{(f(x_i - \bar{X}))^2}{N}} \quad (\text{B.9})$$

$$\sigma_f = \sqrt{\sum_{i=1}^N \frac{f^2(x_i - \bar{X})^2}{N}} \quad (\text{B.10})$$

$$\sigma_f = f \sqrt{\sum_{i=1}^N \frac{(x_i - \bar{X})^2}{N}} \quad (\text{B.11})$$

pero $\sigma = \sqrt{\sum_{i=1}^N \frac{(x_i - \bar{X})^2}{N}}$ entonces:

$$\sigma_f = f\sigma \quad (\text{B.12})$$

1742 De la ecuación B.12 se concluye que al multiplicar un conjunto de datos ω cualquiera
1743 por un escalar f cualquiera, la desviación estándar σ_f del nuevo conjunto ω' es igual
1744 a la desviación estándar σ del conjunto ω por el escalar f .

Adición de una constante Sea σ la desviación estándar de un conjunto de datos ω cualquiera definida como en la ecuación 3.7.

Si se le suma una constante C cualquiera a cada elemento $x_i \in \omega$, la desviación estándar σ_c del nuevo conjunto de datos $\omega' = \omega + C$ se define como:

$$\sigma_c = \sqrt{\sum_{i=1}^N \frac{((x_i + C) - (\bar{X} + C))^2}{N}} \quad (\text{B.13})$$

De la ecuación B.7 se sabe que la media resultante de sumar una constante a un conjunto de datos, es igual a la media del conjunto original más la constante.

$$\sigma_C = \sqrt{\sum_{i=1}^N \frac{(x_i + C - \bar{X} - C)^2}{N}} \quad (\text{B.14})$$

$$\sigma_C = \sqrt{\sum_{i=1}^N \frac{(x_i - \bar{X})^2}{N}} \quad (\text{B.15})$$

pero $\sigma = \sqrt{\sum_{i=1}^N \frac{(x_i - \bar{X})^2}{N}}$ entonces:

$$\sigma_C = \sigma \quad (\text{B.16})$$

1745 De la ecuación B.16 se concluye que la desviación estándar σ de un conjunto de
1746 datos no cambia cuando se suma una constante C cualquiera, a dicho conjunto.

1747 **Cambio de la desviación estándar de un conjunto de datos**

Sea σ_d la desviación estándar deseada y sea σ_a la desviación estándar de una imagen o conjunto de datos I . Se desea cambiar el valor de σ_a para que tenga el valor de σ_d .

De la ecuación B.12 se sabe que la desviación estándar de un conjunto de datos multiplicado por cierto escalar es igual a la desviación estándar original por dicho escalar. Con lo anterior, se define la siguiente relación:

$$\sigma_d = K\sigma_a \quad (\text{B.17})$$

$$K = \sigma_d/\sigma_a \quad (\text{B.18})$$

1748 donde K es el factor o constante por el cual se debe multiplicar a I para que tenga
1749 como desviación estándar a σ_d .

1750 **B.0.1. Cambio de la media de un conjunto de datos**

Sea \bar{X}_a la media de una imagen o conjunto de datos I y sea \bar{X}_d la media que se desea que tenga I .

A partir de la ecuación B.16 se sabe que la desviación estándar de un conjunto de datos no cambia al sumar una constante a dicho conjunto. Por otra parte, se sabe que la media del conjunto analizado es igual a la media original más la constante, de acuerdo a lo descrito por la ecuación B.7.

Para lograr que la *media*(I) sea igual a la media deseada, \bar{X}_d , se sigue el siguiente proceso:

Sea I' una imagen con media igual a cero dada por:

$$I'(x, y) = I(x, y) - \bar{X}_a \quad (\text{B.19})$$

Donde $I(x, y)$ e $I'(x, y)$ son los valores de intensidad de cada pixel y \bar{X}_a es la media de I .

Sea I'' una segunda imagen con media= \bar{X}_d (media deseada), dada por:

$$I''(x, y) = I'(x, y) + \bar{X}_d \quad (\text{B.20})$$

Se tiene entonces:

$$I''(x, y) = I(x, y) - \bar{X}_a + \bar{X}_d \quad (\text{B.21})$$

1751 Se concluye, a partir de la ecuación B.21, que para tener una imagen con la
1752 media deseada, \bar{X}_d , se debe sustraer de la imagen I la media original, \bar{X}_a , y añadir
1753 la media deseada, \bar{X}_d .

1754 Apéndice C

1755 En este apéndice se describen de manera breve los modelos de iluminación utili-
1756 zados en graficación por computadora, así como las técnicas de sombreado.

1757 C.1. Iluminación y sombreado

1758 C.1.1. Modelo de iluminación

1759 Un modelo de iluminación permite cuantificar la luz reflejada en cierto punto
1760 de una superficie de acuerdo a las características de la luz y de dicha superficie. El
1761 modelo de iluminación, es un método que permite calcular la intensidad de luz en
1762 las superficies de manera simplificada y veloz (?).

1763 Para determinar los efectos de la luz sobre cierta superficie, se deben tener en cuenta
1764 las siguientes variables (?)

1765 ■ Parámetros de la fuente de luz:

1766 ● Posición.

1767 ● Forma

1768 ■ Parámetros de la superficie:

1769 ● Posición.

1770 ● Propiedades de reflexión.

1771 ■ Cámara:

1772 ● Posición.

1773 Modelo de iluminación de Phong (Throne, n.d.).

1774 El modelo de iluminación de Phong está determinado por 3 parámetros de la luz:

1775 **Componente ambiental:** Iluminación de fondo.

1776 **Componente difusa:** Iluminación sin brillo y sombras.

1777 **Componente especular:** Reflexiones brillantes.

1778 Iluminación ambiental

La intensidad de luz I_{amb} reflejada en cualquier punto de una superficie está determinada por la siguiente ecuación:

$$I_{amb} = K_a I_a \quad (C.1)$$

1779 Donde I_a es la intensidad de la componente ambiental de la luz y K_a es la propiedad
1780 de reflexión de luz ambiental de la superficie.

1781 Reflexión difusa

La iluminación en un punto p de una superficie depende de el ángulo θ entre el vector normal \vec{N} en ese punto de la superficie y el vector \vec{v} que va del punto p hasta la posición de la fuente de luz.

La reflexión difusa se define a través de la siguiente ecuación:

$$I_{diff} = I_p k_{diff} \cos(\theta) \quad (C.2)$$

1782 Donde I_p es la intensidad la fuente de luz.

1783 k_{diff} es la propiedad de reflexión difusa de la superficie.

1784 θ el ángulo entre los vectores \vec{N} y \vec{v} .




Figura C.1: Reflexión difusa. Imagen tomada de (Throne, n.d.).

1785 Reflexión especular

Con ayuda de este modelo se pueden modelar objetos brillantes como el metal o el plástico. La intensidad de luz reflejada depende de la dirección del vector de reflexión \vec{R} .

La reflexión especular se define como sigue:

$$I_{spec} = I_p k_s \cos(\alpha)^n \quad (C.3)$$

1786 Donde I_p es la intensidad de la componente especular.
 1787 k_s es la propiedad de reflexión especular de la superficie.
 1788 n es un parámetro de intensidad especular que depende del material de la superficie.
 1789 α es el ángulo entre el vector \vec{R} y el vector \vec{v} que va del punto de incidencia a la cámara.




Figura C.2: Reflexión especular. Imagen tomada de (Throne, n.d.).

1790

$$\vec{R} = 2\vec{N}(\vec{N} \cdot \vec{L}) - \vec{L} \quad (\text{C.4})$$

1791 Finalmente, el modelo de iluminación de Phong queda definido de la siguiente
 1792 manera:




Figura C.3: Modelo de Phong que resulta de combinar las 3 componentes del modelo de iluminación (ambiental, difusa y especular). Imagen tomada de (Throne, n.d.).

$$I = I_{amb} + I_{diff} + I_{spec} \quad (\text{C.5})$$

1793 C.1.2. Modelos de Sombreado

1794 Los modelos de sombreado son técnicas o metodologías que permiten iluminar o
1795 colorear cada punto en un modelo 3D . Se tienen 3 tipos de técnicas:

- 1796 1. *Flat shading (Sombreado plano)*
- 1797 2. *Gouraud shading (sombreado de Gouraud)*
- 1798 3. *Phong shading (sombreado de Phong)*

1799 C.1.3. Flat shading

1800 En este método se realiza el cálculo de la iluminación por cada polígono que
compone al modelo.




Figura C.4: Flat shading aplicado a un modelo 3D. Imagen tomada de (*Shading*, n.d.).

1801

1802 C.1.4. Gouraud shading

1803 El color se calcula por cada vértice que compone al modelo 3D. El algoritmo que
1804 describe esta técnica de sombreado es el siguiente:

- 1805 1. Calcular la normal de cada vértice, promediando las normales de cada polígono
1806 al que cada vértice pertenece.
- 1807 2. Aplicar un modelo de iluminación a cada vértice para calcular la intensidad
1808 en ese punto.
- 1809 3. Interpolarse las intensidades de los vértices que componen a un polígono para
1810 obtener los colores sobre la superficie del mismo.




Figura C.5: Gouraud shading aplicado a un modelo 3D. Imagen tomada de (*Shading*, n.d.).

1811 C.1.5. Phong shading

1812 Esta técnica es similar al **Gouraud shading**, solo que en este caso, la intensidad
1813 de la luz se calcula por cada pixel. En lugar de interpolar colores, utilizando esta
1814 técnica se interpolan las normales asociadas a cada vértice.

1815 El algoritmo que describe el método es el siguiente:

- 1816 1. Calcular las normales por cada vértice de un polígono.
- 1817 2. Interpolar las normales a lo largo de la superficie del polígono.
- 1818 3. Aplicar el modelo de iluminación a cada pixel que compone al polígono para
1819 obtener la intensidad en ese punto.




Figura C.6: Phong shading aplicado a un modelo 3D. Imagen tomada de (*Shading*, n.d.).

Apéndice D

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.508	0.602	0.001	0.612	0.00582	0.0536
	-0.101	0.0173	0.00251	-0.0196	0.0127	0.994
	-0.0125	0.00390	0.0033	-0.00165	0.999	-0.0142
2	0.481	0.613	0.00157	0.620	0.0089	0.0845
	-0.189	0.0285	0.00446	-0.0150	0.0246	0.980
	-0.0257	0.00724	0.00483	0.00243	0.999	-0.0303
3	0.44	0.628	0.00110	0.628	0.00885	0.096
	-0.245	0.0297	0.00271	-0.0039	0.0207	0.968
	-0.0301	0.00729	0.00304	0.00451	0.999	-0.0292
4	0.0817	0.649	0.0312	0.553	0.147	0.492
	0.980	-0.0119	-0.0329	0.00323	-0.167	-0.0981
	0.154	-0.0375	-0.023	-0.142	0.970	-0.106
5	0.0356	0.65	0.118	0.255	0.342	0.606
	-0.084	-0.019	0.974	-0.190	-0.0759	-0.040
	0.994	-0.00530	0.0750	-0.0280	-0.0638	-0.0193
6	0.0866	0.655	0.00638	0.588	0.0527	0.461
	0.990	-0.0221	-0.00551	-0.0198	-0.0484	-0.123
	0.0414	-0.0147	0.00147	-0.040	0.996	-0.0496
7	0.533	0.588	0.00122	0.606	0.00755	0.0372
	-0.0677	0.0110	0.00280	-0.0126	0.0198	0.997
	-0.0150	0.0040	0.00297	-0.00185	0.999	-0.0210
8	0.405	0.640	0.00362	0.63	0.0281	0.129
	-0.3	0.0315	0.00944	-0.00182	0.0956	0.930
	-0.0572	0.010	0.00627	0.00704	0.99	-0.12
9	0.401	0.632	0.00511	0.637	0.0332	0.173
	-0.50	0.0637	0.0130	0.018	0.103	0.853
	-0.0970	0.0249	0.00905	0.0341	0.978	-0.179
10	0.426	0.63	0.0135	0.623	0.0431	0.162
	-0.44	0.0847	0.0347	-0.0190	0.142	0.87
	-0.0786	0.0276	0.0249	0.0105	0.975	-0.202
11	0.138	0.643	0.0798	0.543	0.227	0.462
	0.951	-0.0148	-0.0917	0.0150	-0.254	-0.141
	-0.0010	0.000712	0.938	0.000844	-0.345	0.00583
	0.172	0.64	0.0509	0.557	0.178	0.453

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
	0.948	-0.0294	-0.0531	0.00868	-0.179	-0.25
	0.140	-0.0370	-0.0312	-0.183	0.960	-0.148
13	0.384	0.652	0.0150	0.632	0.0523	0.153
	-0.395	0.0183	0.0342	-0.013	0.189	0.897
	-0.0548	0.00599	0.0177	0.00194	0.971	-0.229
14	0.69	0.202	0.00103	0.689	0.00103	0.00807
	-0.15	0.976	0.00355	-0.12	0.00355	0.0697
	0.00386	-0.069	0.000953	0.00496	0.000953	0.997
15	0.275	0.667	0.00404	0.644	0.0585	0.246
	0.857	-0.0736	-0.00667	-0.0941	-0.113	-0.487
	-0.00278	0.0013	0.00177	-0.00016	0.972	-0.231
16	0.457	0.628	0.0268	0.601	0.0984	0.150
	-0.3	0.0135	0.0607	-0.0521	0.500	0.798
	-0.00640	0.00215	0.00959	-0.00290	0.845	-0.533
17	0.406	0.646	0.005	0.632	0.03	0.127
	-0.311	0.0129	0.0106	-0.0105	0.117	0.94
	-0.0650	0.00647	0.0073	0.00340	0.987	-0.144
18	0.344	0.639	0.0224	0.612	0.10	0.289
	0.735	-0.0584	-0.0429	-0.0108	-0.264	-0.620
	0.0474	-0.00613	0.00588	-0.0253	0.937	-0.342
19	0.0219	0.618	0.232	0.160	0.424	0.597
	0.998	-0.00236	-0.0533	-0.00226	-0.0112	-0.00480
	-0.0232	-0.00299	-0.458	0.886	-0.0542	-0.0179
20	0.0175	0.658	0.0686	0.314	0.267	0.62
	-0.0193	-0.014	0.994	-0.0822	-0.0601	-0.0265
	0.998	-0.00167	0.0161	0.000182	-0.0520	-0.00582
21	0.326	0.660	0.00256	0.628	0.0276	0.246
	0.73	-0.0916	-0.00462	-0.0203	-0.0536	-0.669
	-0.0777	0.0281	0.00429	0.0340	0.981	-0.168
22	0.0346	0.651	0.0786	0.310	0.337	0.598
	-0.696	-0.00602	0.71	-0.0750	-0.00223	-0.00679
	0.715	-0.0126	0.688	-0.0928	-0.0697	-0.0306

Cuadro D.1: Vectores propios de **Aleatorias**.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.286	0.656	0.00768	0.634	0.0416	0.285
	0.835	-0.0744	-0.0134	-0.0523	-0.0710	-0.537
	-0.0444	0.0148	0.0118	0.0321	0.97	-0.2
2	0.537	0.596	0.000146	0.596	0.00161	0.0147
	-0.0211	-0.000400	0.000306	-0.00521	0.00334	0.999
	-0.0024	0.000168	0.000339	-0.000554	0.999	-0.00339
3	0.459	0.630	0.00139	0.620	0.0136	0.0779
	-0.168	0.0117	0.00313	-0.0113	0.0315	0.984
	-0.0311	0.00477	0.00344	0.000986	0.998	-0.0374

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
4	0.423	0.639	0.00479	0.626	0.0316	0.135
	-0.384	0.0535	0.0118	0.00169	0.0831	0.917
	-0.0912	0.0221	0.0125	0.0170	0.986	-0.129
5	0.43	0.64	0.00759	0.617	0.0333	0.117
	-0.302	0.0428	0.0211	-0.0185	0.109	0.94
	-0.064	0.015	0.0208	0.00182	0.988	-0.136
6	0.351	0.651	0.00558	0.635	0.044	0.21
	-0.64	0.068	0.0120	0.0238	0.109	0.753
	-0.0802	0.021	0.00835	0.0267	0.97	-0.213
7	0.213	0.656	0.0228	0.616	0.115	0.360
	0.920	-0.0517	-0.0288	-0.0282	-0.165	-0.348
	0.0927	-0.0237	-0.00570	-0.0681	0.971	-0.205
8	0.508	0.607	0.00094	0.607	0.00568	0.0534
	-0.0893	0.00477	0.00182	-0.0177	0.0102	0.995
	-0.0106	0.00182	0.00233	-0.00127	0.999	-0.0112
9	0.273	0.656	0.015	0.630	0.0801	0.298
	0.801	-0.0416	-0.0360	-0.0122	-0.176	-0.568
	0.0356	-0.00413	0.0104	-0.0157	0.967	-0.250
10	0.320	0.661	0.00991	0.643	0.049	0.205
	-0.671	0.0577	0.0251	0.032	0.135	0.724
	-0.0602	0.0135	0.0167	0.0172	0.96	-0.239
11	0.429	0.637	0.00199	0.629	0.0163	0.108
	-0.279	0.0237	0.00455	0.00102	0.039	0.95
	-0.0493	0.00896	0.00482	0.00830	0.997	-0.0552
12	0.435	0.641	0.00146	0.622	0.0141	0.104
	-0.239	0.0205	0.00409	-0.0172	0.0343	0.969
	-0.033	0.00611	0.00462	0.0017	0.998	-0.043
13	0.420	0.637	0.00240	0.631	0.0154	0.134
	-0.390	0.0478	0.00612	0.0151	0.0405	0.918
	-0.0659	0.0161	0.00732	0.0188	0.994	-0.0731
14	0.355	0.649	0.0100	0.627	0.0566	0.234
	-0.693	0.0884	0.0213	0.027	0.134	0.701
	-0.0766	0.0239	0.0156	0.0304	0.960	-0.265
15	0.476	0.621	0.00144	0.616	0.0129	0.078
	-0.171	0.0183	0.00309	-0.0128	0.0279	0.984
	-0.0318	0.00637	0.00345	0.00160	0.998	-0.033
16	0.478	0.61	0.00325	0.617	0.0206	0.0878
	-0.202	0.0256	0.00733	-0.00942	0.0545	0.977
	-0.0507	0.0111	0.00766	0.00426	0.996	-0.0664
17	0.145	0.658	0.0136	0.598	0.0793	0.424
	0.96	-0.0295	-0.016	-0.0210	-0.0948	-0.236
	0.0726	-0.0179	0.00337	-0.0635	0.990	-0.092
18	0.519	0.597	0.00393	0.607	0.0189	0.0613
	-0.107	0.0138	0.00784	-0.0234	0.0474	0.992
	-0.032	0.00711	0.00838	-0.0051	0.998	-0.051

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
19	0.474	0.629	0.0059	0.602	0.0253	0.120
	-0.342	0.10	0.0160	-0.029	0.0707	0.930
	-0.0932	0.0448	0.0222	0.0077	0.987	-0.114
20	0.444	0.633	0.00273	0.624	0.0218	0.104
	-0.241	0.0224	0.00607	-0.01	0.06	0.968
	-0.0481	0.00923	0.00512	0.00254	0.995	-0.0745
21	0.390	0.642	0.00556	0.636	0.0288	0.168
	-0.534	0.0693	0.0139	0.0322	0.0770	0.83
	-0.11	0.0309	0.0161	0.0391	0.977	-0.167
22	0.0774	0.664	0.0183	0.465	0.128	0.564
	0.991	-0.0216	-0.0108	0.00960	-0.0772	-0.1
	0.0729	-0.0225	0.0159	-0.194	0.976	-0.045

Cuadro D.2: Vectores propios de Dalí.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.377	0.654	0.0116	0.633	0.0538	0.160
	-0.443	0.027	0.0294	-0.00310	0.182	0.876
	-0.0666	0.00928	0.0171	0.00716	0.969	-0.235
2	0.439	0.635	0.00233	0.624	0.019	0.114
	-0.287	0.0299	0.00554	-0.00518	0.0469	0.956
	-0.0571	0.0114	0.00576	0.00983	0.996	-0.0663
3	0.340	0.660	0.00815	0.644	0.049	0.171
	-0.48	0.016	0.0227	0.000262	0.259	0.831
	0.00844	0.000390	0.00231	-0.000275	0.95	-0.292
4	0.429	0.642	0.00432	0.625	0.0379	0.10
	-0.254	0.0149	0.00940	-0.00845	0.118	0.959
	-0.0697	0.007	0.00737	0.00345	0.987	-0.140
5	0.41	0.645	0.00280	0.629	0.0321	0.129
	-0.35	0.0315	0.00632	0.00352	0.0935	0.929
	-0.0725	0.012	0.00487	0.0104	0.988	-0.127
6	0.490	0.621	0.00384	0.60	0.0209	0.0555
	-0.101	0.00423	0.00762	-0.0149	0.0628	0.992
	-0.0347	0.00323	0.00761	-0.00360	0.997	-0.066
7	0.364	0.667	0.0123	0.615	0.0731	0.195
	-0.613	0.0823	0.0250	0.00833	0.208	0.756
	-0.0741	0.0186	0.0127	0.0136	0.943	-0.322
8	0.481	0.62	0.011	0.604	0.0540	0.0973
	-0.203	0.0129	0.0235	-0.0250	0.220	0.953
	-0.0645	0.00717	0.0153	-0.00457	0.968	-0.238
9	0.493	0.623	0.00437	0.601	0.0289	0.0646
	-0.104	-0.000332	0.00729	-0.0249	0.100	0.989
	-0.0370	0.00155	0.00572	-0.00779	0.993	-0.104
10	0.192	0.666	0.013	0.594	0.115	0.389
	0.937	-0.0516	-0.0144	-0.0108	-0.13	-0.315

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
	0.0786	-0.0234	0.00169	-0.0651	0.976	-0.188
11	0.445	0.63	0.00335	0.61	0.0173	0.124
	-0.303	0.0384	0.00641	-0.0137	0.0358	0.951
	-0.0547	0.0147	0.00862	0.00741	0.996	-0.0555
12	0.393	0.655	0.00549	0.62	0.044	0.143
	-0.411	0.039	0.0115	0.00150	0.129	0.901
	-0.0838	0.0140	0.00819	0.0100	0.979	-0.180

Cuadro D.3: Vectores propios de **Da Vinci**.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.315	0.663	0.0135	0.640	0.0684	0.213
	-0.711	0.0691	0.0334	0.034	0.214	0.663
	-0.0043	0.00314	0.00935	0.00114	0.949	-0.312
2	0.138	0.659	0.0414	0.60	0.157	0.391
	0.960	-0.0235	-0.0536	-0.0189	-0.200	-0.184
	0.105	-0.0253	-0.567	-0.073	0.80	-0.143
3	0.236	0.658	0.020	0.620	0.122	0.331
	0.873	-0.0486	-0.0319	-0.011	-0.256	-0.408
	0.144	-0.0283	-0.00884	-0.0633	0.946	-0.278
4	0.508	0.614	0.00316	0.599	0.0161	0.0623
	-0.114	0.0177	0.00646	-0.0250	0.0417	0.992
	-0.0303	0.00837	0.00692	-0.00500	0.998	-0.0458
5	0.427	0.645	0.0058	0.620	0.0333	0.122
	-0.324	0.0430	0.0153	-0.0121	0.114	0.937
	-0.0680	0.0162	0.011	0.00548	0.986	-0.14
6	0.215	0.664	0.00593	0.644	0.0652	0.303
	0.902	-0.0511	-0.0101	-0.0458	-0.14	-0.399
	0.0850	-0.0162	0.000336	-0.0367	0.982	-0.157
7	0.194	0.661	0.0147	0.625	0.11	0.347
	0.926	-0.0348	-0.0233	-0.0400	-0.198	-0.314
	0.130	-0.0237	-0.013	-0.0676	0.965	-0.212
8	0.2	0.664	0.00943	0.640	0.0608	0.273
	0.851	-0.0674	-0.017	-0.0543	-0.114	-0.504
	-0.000242	0.00163	0.00723	8.98172e-05	0.975	-0.221
9	0.0310	0.664	0.056	0.330	0.194	0.638
	0.993	-0.00632	-0.0451	0.0378	-0.0887	-0.0303
	0.0556	-0.00986	0.982	-0.169	0.0549	-0.00813
10	0.257	0.657	0.0107	0.624	0.105	0.3
	0.862	-0.0512	-0.017	-0.035	-0.208	-0.456
	0.0871	-0.0164	-0.00112	-0.0441	0.958	-0.26
11	0.425	0.653	0.00270	0.609	0.0252	0.138
	-0.401	0.0817	0.00613	-0.016	0.0597	0.910
	-0.085	0.0295	0.00738	0.0108	0.990	-0.105
12	0.374	0.650	0.00823	0.633	0.0547	0.181

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
	-0.48	0.0273	0.0189	-0.00170	0.163	0.858
	-0.0646	0.00909	0.0111	0.00832	0.972	-0.222
13	0.475	0.625	0.00615	0.613	0.0275	0.0766
	-0.154	0.0081	0.0118	-0.0154	0.0797	0.98
	-0.0487	0.00544	0.0111	-0.00158	0.994	-0.0884
14	0.318	0.655	0.0133	0.635	0.105	0.231
	0.726	-0.0506	-0.0275	-0.0387	-0.335	-0.596
	0.0656	-0.00877	-0.00198	-0.0189	0.902	-0.425

Cuadro D.4: Vectores propios de **Diego Rivera**.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.286	0.656	0.00768	0.634	0.0416	0.285
	0.835	-0.0744	-0.0134	-0.0523	-0.0710	-0.537
	-0.0444	0.0148	0.0118	0.0321	0.97	-0.2
2	0.319	0.661	0.00744	0.620	0.0547	0.269
	0.792	-0.10	-0.0118	-0.0289	-0.0910	-0.592
	-0.158	0.0576	0.0139	0.0990	0.909	-0.367
3	0.138	0.659	0.0414	0.60	0.157	0.391
	0.960	-0.0235	-0.0536	-0.0189	-0.200	-0.184
	0.105	-0.0253	-0.567	-0.073	0.80	-0.143
4	0.459	0.630	0.00139	0.620	0.0136	0.0779
	-0.168	0.0117	0.00313	-0.0113	0.0315	0.984
	-0.0311	0.00477	0.00344	0.000986	0.998	-0.0374
5	0.393	0.653	0.00400	0.61	0.042	0.183
	-0.597	0.111	0.00857	0.0222	0.0978	0.787
	-0.16	0.0552	0.0101	0.0574	0.949	-0.253
6	0.236	0.658	0.020	0.620	0.122	0.331
	0.873	-0.0486	-0.0319	-0.011	-0.256	-0.408
	0.144	-0.0283	-0.00884	-0.0633	0.946	-0.278
7	0.107	0.649	0.0457	0.47	0.221	0.542
	0.974	-0.0142	-0.0423	0.034	-0.171	-0.13
	0.042	-0.00837	0.99	-0.077	-0.0105	-0.0108
8	0.429	0.642	0.00432	0.625	0.0379	0.10
	-0.254	0.0149	0.00940	-0.00845	0.118	0.959
	-0.0697	0.007	0.00737	0.00345	0.987	-0.140
9	0.475	0.623	0.0047	0.615	0.020	0.0835
	-0.148	0.00263	0.00769	-0.0238	0.0449	0.98
	-0.0344	0.00314	0.00752	-0.00306	0.99	-0.050
10	0.467	0.62	0.00650	0.610	0.0340	0.152
	-0.389	0.0567	0.0144	0.00752	0.0865	0.915
	-0.115	0.0284	0.0180	0.0404	0.981	-0.144
11	0.481	0.62	0.011	0.604	0.0540	0.0973
	-0.203	0.0129	0.0235	-0.0250	0.220	0.953
	-0.0645	0.00717	0.0153	-0.00457	0.968	-0.238

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
12	0.616	0.498	0.00103	0.607	0.00689	0.038
	-0.458	0.844	0.00277	-0.235	0.0178	0.139
	0.0318	-0.14	0.0007	0.0201	0.00462	0.989
13	0.181	0.654	0.0797	0.576	0.211	0.394
	0.933	-0.0262	-0.111	-0.00721	-0.27	-0.206
	0.0220	-0.00354	0.953	-0.0116	-0.300	-0.0187
14	0.178	0.659	0.0171	0.592	0.112	0.410
	0.943	-0.0316	-0.0278	-0.0402	-0.223	-0.239
	0.177	-0.0274	-0.0458	-0.0815	0.962	-0.178

Cuadro D.5: Vectores propios de **Combinadas**.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.282	0.642	0.0130	0.599	0.103	0.369
	0.876	-0.06	-0.0156	-0.0368	-0.132	-0.456
	0.0402	-0.00789	0.00401	-0.0553	0.977	-0.201
2	0.319	0.661	0.00744	0.620	0.0547	0.269
	0.792	-0.10	-0.0118	-0.0289	-0.0910	-0.592
	-0.158	0.0576	0.0139	0.0990	0.909	-0.367
3	0.320	0.662	0.017	0.587	0.0935	0.323
	0.825	-0.12	-0.022	0.00824	-0.13	-0.532
	-0.10	0.0424	0.0177	0.0773	0.910	-0.391
4	0.393	0.653	0.00400	0.61	0.042	0.183
	-0.597	0.111	0.00857	0.0222	0.0978	0.787
	-0.16	0.0552	0.0101	0.0574	0.949	-0.253
5	0.307	0.658	0.0149	0.640	0.072	0.237
	-0.725	0.0479	0.0345	0.0326	0.199	0.654
	-0.000444	0.00132	0.00894	-0.000863	0.956	-0.29
6	0.29	0.665	0.00341	0.649	0.0430	0.214
	-0.695	0.0420	0.00870	0.0337	0.130	0.704
	-0.0133	0.00278	0.00242	0.00283	0.980	-0.195
7	0.126	0.657	0.0257	0.552	0.185	0.459
	0.971	-0.0226	-0.0238	-0.00368	-0.167	-0.161
	0.130	-0.0366	-0.136	-0.157	0.953	-0.17
8	0.204	0.659	0.0433	0.589	0.172	0.380
	0.919	-0.0371	-0.0583	-0.00797	-0.23	-0.303
	0.140	-0.0301	-0.112	-0.0997	0.936	-0.28
9	0.433	0.635	0.00635	0.622	0.049	0.13
	-0.315	0.0198	0.0127	-0.0162	0.155	0.935
	-0.0761	0.0103	0.00837	0.0051	0.979	-0.188
10	0.379	0.647	0.0151	0.631	0.0851	0.176
	-0.568	0.0518	0.0347	0.0343	0.281	0.770
	-0.0754	0.0136	0.0164	0.0168	0.916	-0.392
11	0.378	0.652	0.0110	0.621	0.0618	0.202
	-0.609	0.0751	0.023	0.0242	0.1	0.774

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
	-0.121	0.0317	0.0199	0.039	0.948	-0.286

Cuadro D.6: Vectores propios de **Monet**.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.442	0.635	0.00303	0.621	0.0328	0.10
	-0.305	0.0357	0.00701	0.00891	0.0908	0.947
	-0.0889	0.0162	0.00684	0.016	0.987	-0.124
2	0.305	0.65	0.0161	0.610	0.132	0.291
	0.807	-0.0655	-0.0270	-0.0278	-0.272	-0.51
	0.056	-0.00993	-0.00108	-0.0297	0.917	-0.392
3	0.422	0.634	0.0101	0.621	0.0693	0.166
	-0.496	0.061	0.0240	0.0265	0.212	0.838
	-0.132	0.0274	0.0161	0.0426	0.936	-0.319
4	0.347	0.651	0.00774	0.631	0.048	0.230
	-0.70	0.0711	0.0157	0.0555	0.101	0.692
	-0.136	0.0334	0.0186	0.0722	0.944	-0.287
5	0.234	0.663	0.00992	0.631	0.0677	0.318
	0.881	-0.0486	-0.0159	-0.0349	-0.10	-0.456
	0.0208	-0.00378	0.00598	-0.0145	0.981	-0.187
6	0.457	0.632	0.00150	0.616	0.0245	0.096
	-0.220	0.0188	0.00311	-0.00985	0.0593	0.973
	-0.0578	0.00906	0.00332	0.00560	0.995	-0.0739
7	0.616	0.498	0.00103	0.607	0.00689	0.038
	-0.458	0.844	0.00277	-0.235	0.0178	0.139
	0.0318	-0.14	0.0007	0.0201	0.00462	0.989
8	0.357	0.645	0.00875	0.630	0.0511	0.236
	-0.694	0.0735	0.0187	0.0454	0.10	0.705
	-0.227	0.056	0.0219	0.139	0.886	-0.373
9	0.359	0.65	0.00533	0.635	0.0448	0.20
	-0.572	0.0448	0.0125	0.0131	0.113	0.810
	-0.0844	0.016	0.00996	0.0243	0.976	-0.197
10	0.154	0.656	0.0137	0.600	0.106	0.416
	0.958	-0.0282	-0.0178	-0.0245	-0.157	-0.233
	0.125	-0.0258	0.000968	-0.0864	0.97	-0.131
11	0.0725	0.65	0.0316	0.489	0.172	0.542
	0.990	-0.0109	-0.029	-0.00825	-0.112	-0.0743
	0.0209	-0.00456	0.997	-0.027	-0.063	-0.0109
12	0.188	0.64	0.0255	0.57	0.12	0.448
	0.947	-0.041	-0.0241	-0.0104	-0.116	-0.292
	0.0909	-0.02	0.0183	-0.142	0.981	-0.0876
13	0.467	0.62	0.00650	0.610	0.0340	0.152
	-0.389	0.0567	0.0144	0.00752	0.0865	0.915
	-0.115	0.0284	0.0180	0.0404	0.981	-0.144
	0.276	0.658	0.00956	0.629	0.0871	0.291

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
	0.832	-0.0543	-0.0165	-0.0442	-0.190	-0.515
	0.0514	-0.00897	-0.00138	-0.0218	0.961	-0.268
15	0.388	0.645	0.00425	0.633	0.0351	0.172
	-0.494	0.0494	0.00974	0.0127	0.0870	0.863
	-0.0883	0.0186	0.00905	0.0217	0.984	-0.151
16	0.233	0.653	0.0214	0.605	0.125	0.368
	0.903	-0.0514	-0.0261	-0.0196	-0.16	-0.39
	0.0755	-0.0183	-0.00368	-0.0680	0.967	-0.231
17	0.430	0.637	0.00597	0.6	0.0556	0.169
	-0.453	0.0734	0.011	-0.0130	0.143	0.87
	-0.109	0.0306	0.00915	0.0171	0.969	-0.217
18	0.129	0.654	0.0264	0.580	0.140	0.444
	0.965	-0.0223	-0.0306	0.00163	-0.165	-0.196
	0.134	-0.0339	-0.0112	-0.110	0.97	-0.150
19	0.396	0.636	0.00875	0.627	0.0490	0.203
	-0.637	0.0852	0.0194	0.0619	0.121	0.753
	-0.18	0.0476	0.0203	0.0976	0.923	-0.318
20	0.23	0.646	0.0329	0.590	0.147	0.392
	0.910	-0.0515	-0.0377	-0.0194	-0.17	-0.368
	0.105	-0.0272	0.00168	-0.129	0.967	-0.189

Cuadro D.7: Vectores propios de **Picasso**.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.417	0.638	0.00627	0.629	0.0378	0.143
	-0.427	0.050	0.014	0.0212	0.103	0.896
	-0.11	0.0237	0.0153	0.0282	0.978	-0.168
2	0.181	0.654	0.0797	0.576	0.211	0.394
	0.933	-0.0262	-0.111	-0.00721	-0.27	-0.206
3	0.0220	-0.00354	0.953	-0.0116	-0.300	-0.0187
	0.249	0.668	0.00734	0.627	0.0696	0.302
	0.868	-0.060	-0.0115	-0.0371	-0.112	-0.478
4	0.00348	0.000271	0.00330	-0.00266	0.974	-0.222
	0.42	0.640	0.00871	0.61	0.0695	0.132
	-0.342	0.0214	0.0176	-0.00889	0.289	0.893
5	-0.0662	0.00746	0.00763	0.00308	0.94	-0.331
	0.190	0.663	0.0175	0.626	0.108	0.344
	0.929	-0.0340	-0.0269	-0.0396	-0.176	-0.318
6	0.104	-0.0206	-0.0257	-0.0553	0.967	-0.220
	0.475	0.623	0.0047	0.615	0.020	0.0835
	-0.148	0.00263	0.00769	-0.0238	0.0449	0.98
7	-0.0344	0.00314	0.00752	-0.00306	0.99	-0.050
	0.364	0.650	0.0243	0.626	0.0842	0.211
	-0.583	0.041	0.0597	0.000189	0.270	0.762
	-0.0287	0.00562	0.0194	0.00432	0.934	-0.354

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
8	0.307	0.666	0.00787	0.636	0.0822	0.223
	-0.725	0.053	0.0176	0.0378	0.244	0.639
	0.00737	2.85796e-05	0.00200	-0.00200	0.937	-0.349
9	0.181	0.654	0.0226	0.593	0.133	0.409
	0.945	-0.0349	-0.0265	-0.0203	-0.158	-0.280
	0.113	-0.0275	-0.00323	-0.115	0.973	-0.156
10	0.481	0.628	0.000824	0.607	0.0147	0.0625
	-0.114	0.0037	0.00131	-0.0161	0.0296	0.992
	-0.0270	0.002	0.00127	-0.00181	0.999	-0.0330
11	0.503	0.619	0.00197	0.601	0.0165	0.0404
	-0.0661	0.000330	0.00333	-0.0132	0.0466	0.996
	-0.0252	0.00118	0.0031	-0.0042	0.998	-0.0484
12	0.512	0.616	0.0134	0.593	0.0379	0.0617
	-0.112	0.0135	0.0264	-0.0324	0.222	0.967
	-0.0402	0.00702	0.0168	-0.0113	0.972	-0.229
13	0.199	0.657	0.0284	0.607	0.159	0.363
	0.929	-0.0361	-0.036	-0.0331	-0.221	-0.288
	0.137	-0.0316	-0.0609	-0.0999	0.947	-0.262
14	0.478	0.626	0.00251	0.611	0.0162	0.0662
	-0.119	0.0027	0.00422	-0.0175	0.0339	0.992
	-0.029	0.00254	0.00447	-0.00227	0.998	-0.037

Cuadro D.8: Vectores propios de **Renoir**.

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
1	0.017	0.663	0.0390	0.293	0.247	0.641
	0.997	-0.00184	-0.0340	0.0127	-0.0530	-0.00789
	0.0333	-0.00607	0.996	-0.0747	-0.0299	-0.00948
2	0.135	0.647	0.0785	0.516	0.232	0.484
	0.960	-0.0163	-0.116	0.00394	-0.220	-0.125
	0.0749	-0.0114	0.981	-0.0425	-0.167	-0.0392
3	0.300	0.667	0.0145	0.60	0.0684	0.305
	0.794	-0.0850	-0.0236	0.00942	-0.118	-0.588
	-0.0354	0.0136	0.0125	0.0166	0.968	-0.245
4	0.107	0.649	0.0457	0.47	0.221	0.542
	0.974	-0.0142	-0.0423	0.034	-0.171	-0.13
	0.042	-0.00837	0.99	-0.077	-0.0105	-0.0108
5	0.523	0.600	0.0174	0.597	0.0469	0.0802
	-0.128	0.00903	0.0337	-0.0454	0.245	0.959
	-0.038	0.00548	0.020	-0.013	0.966	-0.254
6	0.0285	0.652	0.124	0.312	0.272	0.621
	0.886	0.0085	-0.429	0.152	-0.0824	-0.00418
	0.447	-0.0243	0.869	-0.190	-0.0719	-0.041
7	0.365	0.652	0.0116	0.636	0.0508	0.179
	-0.503	0.0376	0.0275	-0.00213	0.164	0.84

Pintura	ASM	Correlación	Contraste	Homogeneidad	Disimilitud	Entropía
	-0.0536	0.00926	0.0145	0.00606	0.973	-0.221
8	0.270	0.657	0.0221	0.607	0.148	0.32
	0.841	-0.0413	-0.0399	-0.0243	-0.328	-0.424
	0.157	-0.022	-0.0373	-0.0661	0.907	-0.380
9	0.35	0.650	0.00965	0.628	0.0539	0.226
	-0.643	0.0644	0.0200	0.0177	0.126	0.751
	-0.075	0.0178	0.0141	0.0239	0.969	-0.230
10	0.484	0.622	0.00863	0.606	0.0332	0.0967
	-0.165	0.00341	0.014	-0.0329	0.0820	0.982
	-0.0489	0.00448	0.0141	-0.00	0.994	-0.0917
11	0.178	0.659	0.0171	0.592	0.112	0.410
	0.943	-0.0316	-0.0278	-0.0402	-0.223	-0.239
	0.177	-0.0274	-0.0458	-0.0815	0.962	-0.178
12	0.0806	0.647	0.0654	0.461	0.253	0.541
	0.979	-0.00891	-0.0715	0.0329	-0.167	-0.0764
	0.0633	-0.0119	0.99	-0.0750	-0.0569	-0.0246
13	0.445	0.630	0.000798	0.617	0.025	0.146
	-0.269	0.00520	0.00118	-0.0412	0.0499	0.960
	-0.0396	0.00402	0.000967	-0.00121	0.997	-0.0630
14	0.326	0.655	0.00788	0.649	0.053	0.195
	-0.681	0.0604	0.01	0.0541	0.171	0.706
	-0.0376	0.00908	0.00882	0.0115	0.961	-0.271
15	0.314	0.64	0.0250	0.623	0.101	0.28
	0.759	-0.0547	-0.0470	-0.0106	-0.245	-0.598
	0.0379	-0.00493	0.00241	-0.0140	0.940	-0.336
16	0.287	0.655	0.0305	0.598	0.148	0.326
	0.773	-0.0371	-0.0594	0.00725	-0.493	-0.391
	0.301	-0.0350	-0.0810	-0.0685	0.836	-0.443

Cuadro D.9: Vectores propios de Van Gogh.

1821

Bibliografía

- 1822 Bambach, C. (2002), ‘Leonardo da vinci’. Consultado el 3 de mayo de 2017, de
1823 http://www.metmuseum.org/toah/hd/leon/hd_leon.htm.
- 1824 Bhatia, P. K. (2008), *Computer Graphics*, 3 edn, I.K international Publishing House
1825 Pvt. Ltd., New Dheli, India.
- 1826 Blotta, E., Bouchet, A., Ballarin, V. and Pastore, J. (2011), ‘Enhancement of medical
1827 images in hsi color space’, *Journal of Physics: Conference Series*. 332 .
- 1828 Cetinic, E. and Grgic, S. (2013), ‘Automated painter recognition based on image
1829 feature extraction’, *ELMAR, 2013 55th International Symposium* .
- 1830 Cetinic, E. and Grgic, S. (2016), ‘Genre classification of paintings’, *2016 Internatio-
1831 nal Symposium ELMAR* .
- 1832 *Chiaroscuro* (n.d.). Consultado el 25 de septiembre de 2017, de
1833 <https://www.artsy.net/gene/chiaroscuro>.
- 1834 *Claude Monet. Obra y biografía* (n.d.). Consultado el 4 de mayo de 2017 de,
1835 <http://www.artespana.com/monet.htm>.
- 1836 Condorovici, R., Florea, C. and Vertan, C. (2013), ‘Author identification for digitized
1837 painting collections’, *Signals, Circuits and Systems (ISSCS), 2013 International
1838 Symposium on* .
- 1839 *Cubism* (n.d.). Consultado el 7 de mayo de 2017, de [http://www.visual-arts-
1840 cork.com/history-of-art/cubism.htm](http://www.visual-arts-cork.com/history-of-art/cubism.htm).
- 1841 *Cubism - The First Style of Abstract Art* (n.d.). Consultado el 6 de mayo de 2017,
1842 de http://www.artfactory.com/art_appreciation/art_movements/cubism.htm.
- 1843 Culjak, M., Mikus, B., Jez, K. and Hadjic, S. (2011), ‘Classification of art paintings
1844 by genre’, *MIPRO, 2011 Proceedings of the 34th International Convention* .
- 1845 *Da Vinci - The Artist* (n.d.). Consultado el 3 de mayo de 2017, de la página web
1846 del Museo de ciencia de Boston <https://www.mos.org/leonardo/artist>.
- 1847 Devaney, R. L. (1995), ‘Fractal dimension’. Consultado el 30 de agosto de 2017, de
1848 <http://math.bu.edu/DYSYS/chaos-game/node6.html>.
- 1849 *Diego Rivera* (n.d.). Consultado el 4 de mayo de 2017, de la página web del museo
1850 Anahuacalli en México <http://museoanahuacalli.org.mx/diegorivera/index.html>.

- 1851 Fabbri, R., Costa, L. D., Torelli, J. and Bruno, O. (2008), ‘2d euclidean distance
1852 transform algorithms: A comparative survey’, *ACM Computing Surveys*, Vol. 40,
1853 No. 1, Article 2 .
- 1854 González, R. and Woods, R. C. (2007), *Digital Image Processing*, tercera edn, Pear-
1855 son education. pp. 142.
- 1856 Grevera, G. (2004), ‘The ”dead reckoning” signed distance transform’, *Computer*
1857 *Vision an Image Understanding* 95 .
- 1858 Gruber, D. (2000), ‘The mathematics of the 3d rotation matrix’. Consultado el 23
1859 de abril de 2017, de <https://www.fastgraph.com/makegames/3drotation/>.
- 1860 Hajek, M., Dezertpva, M., Materka, A. and Lerski, R. (2006), ‘Texture analysis for
1861 magnetic resonance imaging’, *Med4 publishing* .
- 1862 Hall-Beyer, M. (2017), Glcm texture: A tutorial v. 3.0, Technical report, University
1863 of Calgary.
- 1864 Huang, D., Shan, C., Ardebilian, M., Wang, Y. and Chen, L. (2011), ‘Local binary
1865 patterns and its application to facila image analysis: A survey’, *IEEE Transactions*
1866 *on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* .
- 1867 *Impresionismo* (n.d.). Consultado el 7 de mayo de 2017, de
1868 http://www.spanisharts.com/history/del_impres.s.XX/impresionismo/impresionismo.html.
- 1869 Jain, R. and Schunk, R. K. B. G. (1995), *Machine Vision*, McGrawHill.
- 1870 Kaufman, A., Cohen, D. and Yagel, R. (1993), ‘Volume graphics’, *Computer* .
- 1871 Khorsheed, J. A. and Yurtkan, K. (2016), ‘Analysis of local binary patterns for face
1872 recognition under varying facial expressions’, *Signal Processing and Communica-*
1873 *tion Application Conference (SIU)* .
- 1874 Kim, D., Son, S.-W. and Jeong, H. (2014), ‘Large-scale quantitative analysis of
1875 painting arts’, *Scientific Reports* 4 .
- 1876 Knudsen, J. M. and Hjorth, P. G. (2000), *The Center-of-Mass Theorem*, Springer
1877 Berlin Heidelberg, Berlin, Heidelberg, pp. 193–218.
- 1878 Kovacs, E. (2012), ‘Rotation about an arbitrary axis and reflection through an ar-
1879 bitrary plane’, *Annales Mathematicae et Informaticae* .
- 1880 Lahdenoja, O., Poikionen, J. and Laiho, M. (2013), ‘Towards understanding the
1881 formation of uniform local binary patterns’, *ISRN Machine Vision* .
- 1882 Ledley, R. S., Buas, M. and Golab, T. (1990), ‘Fundamentals of true-color image pro-
1883 cessing’, *Pattern Recognition, 1990. Proceedings., 10th International Conference*
1884 *on* .

- 1885 Lenon, F. E., Cianci, G. C., Cipriani, N. A., Hensing, T. A., Zhang, H. J., Chen,
1886 C.-T., Murgu, S. D., Vokes, E. E., Vannier, M. W. and Salgia, R. (2015), ‘Lung
1887 cancer -a fractal viewpoint’, *Nature Reviews Clinical Oncology* 12 .
- 1888 Liao, S., Law, M. W. K. and Chung, A. C. (2009), ‘Dominant local binary patterns
1889 for texture classification’, *IEEE Transactions on Image Processing* .
- 1890 Marchenko, Y., Chua, T.-S. and Aristarkhova, I. (2005), ‘Analysis and retrieval of
1891 paintings using artistic color concepts’, *Multimedia and Expo, 2005. ICME 2005.*
1892 *IEEE International Conference on* .
- 1893 Materka, A. and Strzelecki, M. (1998), ‘Texture analysis methods - a review’, *COST*
1894 *B11 report* .
- 1895 McKay, B. and McKay, K. (2010), ‘The basics of art: The renaissance’. Consulta-
1896 do el 6 de mayo de 2017 de, [http://www.artofmanliness.com/2010/07/16/man-](http://www.artofmanliness.com/2010/07/16/man-knowledge-the-basics-of-art-the-renaissance/)
1897 [knowledge-the-basics-of-art-the-renaissance/](http://www.artofmanliness.com/2010/07/16/man-knowledge-the-basics-of-art-the-renaissance/).
- 1898 Medellin, H. (n.d.), ‘Transformaciones 3d’. Consultado el
1899 1 de mayo de 2017 de [http://galia.fc.uaslp.mx/mede-](http://galia.fc.uaslp.mx/medellin/Applets/Trans3D/transformaciones_en_3d.htm)
1900 [llin/Applets/Trans3D/transformaciones_en_3d.htm](http://galia.fc.uaslp.mx/medellin/Applets/Trans3D/transformaciones_en_3d.htm).
- 1901 Moffat, C. (2011), ‘The origins of surrealism’. Consultado el 6 de mayo
1902 de 2017 de, [http://www.arthistoryarchive.com/arthistory/surrealism/Origins-of-](http://www.arthistoryarchive.com/arthistory/surrealism/Origins-of-Surrealism.html)
1903 [Surrealism.html](http://www.arthistoryarchive.com/arthistory/surrealism/Origins-of-Surrealism.html).
- 1904 Muñoz, D. R. (2004), *Manual de estadística*. pp. 17-19.
- 1905 Ojeda, L. R. (2007), *Probabilidad y estadística básica para ingenieros*, Escuela Su-
1906 perior Politécnica del Litoral, Instituto de Ciencias Matemáticas. pp. 171.
- 1907 Pacifici, S. (2012), ‘Análisis de densidades mamográficas en espacio rgb’, *Imagen*
1908 *diagnóstica* .
- 1909 Péraire, J. and Widnall, S. (2008), Lecture 126-3d rigid body dyna-
1910 mics: The inertia tensor. Consultado el 22 de febrero de 2017 de,
1911 <https://pdfs.semanticscholar.org/d2b5/e126c3d4bd54e39ee134b1cc28227b99a2b8.pdf>.
- 1912 *Pierre-Auguste Renoir* (n.d.). Consultado el 5 de mayo de 2017, de
1913 la página web del museo nacional Thyssen Bornemisza en España:
1914 <https://www.museothyssen.org/coleccion/artistas/renoir-pierre-auguste>.
- 1915 Pietikäinen, M., Hadid, A., Zhao, G. and Ahonen, T. (2011), *Local Binary Patterns*
1916 *for Still Images*, Springer London, London, chapter 2, pp. 13–47.
- 1917 Poole, D. (2011), *Álgebra lineal. Una Introducción moderna*, tercera edn, Cengage
1918 learning. pp. 265.
- 1919 Pérez, R. (2015), ‘Los diez experimentos de la física que cambiaron la historia’. Con-
1920 sultado el 2 de enero de 2018 de [https://www.elconfidencial.com/tecnologia/2015-](https://www.elconfidencial.com/tecnologia/2015-08-09/los-diez-experimentos-fisicos-que-cambiaron-el-mundo_956989/)
1921 [08-09/los-diez-experimentos-fisicos-que-cambiaron-el-mundo_956989/](https://www.elconfidencial.com/tecnologia/2015-08-09/los-diez-experimentos-fisicos-que-cambiaron-el-mundo_956989/).

- 1922 Puthenputhussery, A. and Liu, Q. L. C. (2016), ‘Color multi-fusion fisher vector
1923 feature for fin art painting categorization and influence analysis’, *Applications of*
1924 *Computer Vision (WACV), 2016 IEEE Winter Conference on* .
- 1925 *Renaissance* (n.d.). Consultado el 6 de mayo de 2017, de
1926 <https://www.britannica.com/event/Renaissance>.
- 1927 Renzetti, F. and Zortea, I. (2011), ‘Use of a gray level co-ocurrence matriz to cha-
1928 racterize duplex stainless steel phases microstructure’, *Frattura ed Integrità Strut-*
1929 *turale* .
- 1930 Robinson, A. (2017), ‘How to calculate sphericity’. Consultado el 11 de septiembre
1931 de 2017, de <http://sciencing.com/calculate-sphericity-5143572.html>.
- 1932 Saleh, B. and Elgammal, A. (2015), ‘A unified framework for painting classification’,
1933 *2015 IEEE International Conference on Data Mining Workshop (ICDMW)* .
- 1934 *Salvador Dalí* (n.d.). Consultado el 4 de mayo de 2017, de la página web del museo
1935 Moco en Ámsterdam <https://www.mocomuseum.com/dali>.
- 1936 Schwarz, M. and Seidel, H.-P. (2010), ‘Fast parallel surface voxelization on gpus’,
1937 *ACM Transactions on Graphics* .
- 1938 *Shading* (n.d.), <http://ruh.li/GraphicsShading.html> consultado el 2 de mayo de 2017.
- 1939 Shapiro, L. G. and Stockman, G. C. (2001), *Computer Vision*, Pearson.
- 1940 Sharma, M. and Singh, S. (2001), ‘Evaluation of texture methods for image analy-
1941 sis’, *Intelligent Information Systems Conference, The Seventh Australian and New*
1942 *Zealand 2001* .
- 1943 Smith, L. I. (2002), ‘A tutorial on principal components analysis’,
1944 <http://faculty.iiit.ac.in/mkrishna/PrincipalComponents.pdf> Consultado el
1945 29 de enero de 2017.
- 1946 *Surrealism* (n.d.). Consultado el 6 de mayo de 2017, de
1947 <http://www.theartstory.org/movement-surrealism.htm>.
- 1948 Szalay, J. (2016), ‘The renaissance: The ‘rebirth’ of science & culture’,
1949 <http://www.livescience.com/55230-renaissance.html> consultado el 6 de mayo de
1950 2017.
- 1951 Taji, T. S. and Gore, D. V. (2013), ‘Overview of texture image segmentation tech-
1952 niques’, *International Journal of Advanced Research in Computer Science and*
1953 *software Engineering* .
- 1954 *Three-Dimensional Rotation Matrices* (2012). Consultado el 23 de abril de 2017, de
1955 http://scipp.ucsc.edu/haber/ph216/rotation_12.pdf.
- 1956 Throne, T. (n.d.), ‘Illumination and shading’,
1957 <http://www.inf.ed.ac.uk/teaching/courses/cg/lectures/slides5.pdf> consultado
1958 el 2 de mayo de 2017.

- 1959 *Vincent van Gogh: Biografía* (n.d.). Consultado el 5 de mayo de 2017, de
1960 <http://www.vangoghgallery.com/es/misc/biografia.html>.
- 1961 Wagner, P. (n.d.), 'Local binary patterns'. Consultado el 23 de agosto de 2017, de
1962 http://bytefish.de/blog/local_binary_patterns/.
- 1963 *what is an art movement?* (n.d.). Consultado el 6 de mayo de 2017, de
1964 http://www.artyfactory.com/art_appreciation/art_movements/art_movements.htm.
- 1965 Widjaja, I., Leow, K. W. and Wu, F.-C. (2003), 'Identifying painters from color
1966 profiles of skin patches in painting images', *Image Processing, 2003. ICIP 2003.*
1967 *Proceedings. 2003 International Conference o* .
- 1968 Wijewickrema, S. and Paplinski, A. (2005), 'Principal component analysis for the
1969 approximation of an image as an ellipse', *WSCG POSTER proceedings* .
- 1970 Yan, P. and Kassim, A. (2004), 'Medical image segmentation using minimal path
1971 deformable models with implicit shape priors', *IEEE TRANSACTIONS ON IN-*
1972 *FORMATION TECHNOLOGY IN BIOMEDICINE, VOL. 10, NO. 4* .
- 1973 Yang, B. and Xu, D. (2011), 'Learning to recognize the art style of paintings
1974 using multi-cues', *Information Technology, Computer Engineering and Manage-*
1975 *ment Sciences (ICM), 2011 International Conference on* .
- 1976 Zayed, N. and Elnerm, H. A. (2015), 'Statistical analysis of haralick texture features
1977 to discriminate lung abnormalities', *International Journal od Biomedical Imaging*
1978 .
- 1979 Zujovic, J., Gandy, L., FriedMan, S., Pardo, B. and Pappas, T. (2009), 'Classifying
1980 paintings by artistic genre: An analysis of features & classifiers', *MMSP* .