



INSTITUTO POLITÉCNICO NACIONAL

**CENTRO DE INVESTIGACIÓN Y DESARROLLO
DE TECNOLOGÍA DIGITAL**

**“Extracción de características para modelar una nueva representación
de la textura del iris en un sistema biométrico”**

T E S I S

QUE PARA OBTENER EL GRADO DE:

Maestría en Ciencias en Sistemas Digitales

PRESENTA:

Ing. Lester Arturo Oropesa Morales

DIRECTOR DE TESIS:

Dra. Mireya Saraí García Vázquez



México, Tijuana. Baja California. Noviembre, 2016.



INSTITUTO POLITÉCNICO NACIONAL

SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

ACTA DE REVISIÓN DE TESIS

En la Ciudad de Tijuana, B.C. siendo las 16:00 horas del día 22 del mes de noviembre del 2016 se reunieron los miembros de la Comisión Revisora de la Tesis, designada por el Colegio de Profesores de Estudios de Posgrado e Investigación de CITEDI

para examinar la tesis titulada:

Extracción de características para modelar una nueva representación de la textura del iris en un sistema biométrico

Presentada por el alumno:

OROPESA

Apellido paterno

MORALES

Apellido materno

LESTER ARTURO

Nombre(s)

Con registro:

A	1	5	0	1	2	8
---	---	---	---	---	---	---

aspirante de:

MAESTRÍA EN CIENCIAS EN SISTEMAS DIGITALES

Después de intercambiar opiniones, los miembros de la Comisión manifestaron **APROBAR LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA

Directores de Tesis

DRA. MIREYA SARAÍ GARCÍA
VÁZQUEZ

DR. LUIS TUPAK AGUILAR BUSTOS

DR. ALEJANDRO ÁLVARO RAMÍREZ ACOSTA

M. en C. ISAURA GONZÁLEZ RUBIO ACOSTA

DR. EDUARDO GAREA LLANO

PRESIDENTE DEL COLEGIO DE PROFESORES

DR. JULIO CÉSAR ROLÓN GARRIDO





INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESIÓN DE DERECHOS

En la Ciudad de Tijuana, Baja California, el día 22 del mes de Noviembre del año 2016, el (la) que suscribe Lester Arturo Oropesa Morales alumno(a) del Programa de MAESTRÍA EN CIENCIAS EN SISTEMAS DIGITALES, con número de registro A156128, adscrito(a) al CENTRO DE INVESTIGACIÓN Y DESARROLLO DE TECNOLOGÍA DIGITAL, manifiesta que es el autor intelectual del presente trabajo de Tesis bajo la dirección de Dra. Mirya Saraí García Vázquez y cede los derechos del trabajo titulado Extracción de características para modelar una nueva representación de la textura del iris en un sistema biométrico, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del (de la) autor(a) y/o director(es) del trabajo. Este puede ser obtenido escribiendo a las siguientes direcciones Av. Instituto Politécnico Nacional No. 1310 Col Nueva Tijuana, Tijuana, Baja California, México. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.


Lester Arturo Oropesa Morales
Nombre y firma del alumno(a)

Dedicatoria

Esta tesis se la dedico a mi familia por el amor, comprensión y consejos. En especial a mis padres que supieron guiarme por el buen camino, darme fuerzas para seguir adelante, ser mi fuente de inspiración y enseñarme a encarar las adversidades sin perder nunca la dignidad.

Por creer en mí y estar, aunque en la distancia, en todo momento a mi lado.

Agradecimientos

Son muchas las personas que están involucradas y han contribuido al desarrollo de esta investigación. Sin embargo, en primer lugar, agradezco a mi tutora de tesis Dra. Mireya Saraí García Vázquez por su apoyo. A mi asesor de tesis Dr. Alejandro Álvaro Ramírez Acosta por estar en todo momento, por sus comentarios, exigencias y enseñanzas hacia mí durante el desarrollo del trabajo. Agradezco por las horas de su tiempo dedicadas a la corrección de los artículos y la tesis desarrollada.

Al comité tutorial por sus revisiones, correcciones y comentarios. Al coordinador de posgrado Mr. Luis Miguel Zamudio Fuentes por su incondicional apoyo en los debates, artículos, trámites y documentos.

Agradezco al Consejo de Ciencia y Tecnología (CONACYT), Instituto Politécnico Nacional, en especial al Centro de Investigación y Desarrollo de Tecnología Digital por el apoyo, patrocinio y haberme aceptado en sus programas.

A todos los profesores del programa de maestría. Al Dr. Eduardo Garea-Llano por el intercambio de ideas, correcciones, comentarios transmitidos para la investigación.

A los estudiantes de estancias académicas y programa “Delfín” por haber sido partícipes de algunas tareas relacionadas con la investigación.

A mis maestros por haber compartido sus conocimientos, ampliar mis horizontes, sembrar en mí el deseo de tener nuevo conocimiento y la búsqueda de la verdad en las cosas. En especial a mi profesor y amigo Dr. Yuniol Alvarez Betancourt por su apoyo en mi carrera profesional.

A mis queridos compañeros de trabajo y de clase, muchos de los cuales son mis amigos y me han permitido compartir en parte de sus vidas.

Resumen

Desde hace un poco más de dos décadas, el reconocimiento basado en la textura del iris ha sido estudiado desarrollándose sistemas biométricos de reconocimiento de personas en diversas áreas tanto sociales como industriales. El iris es uno de los rasgos biométricos más confiables para el reconocimiento de personas. Esto se debe principalmente a su estabilidad, su invariancia en el tiempo y por supuesto a la unicidad de los patrones de textura que se tienen en los iris de las personas. Sin embargo, existen etapas dentro del sistema de reconocimiento basado en iris que aun requieren mayor robustez, debido a que uno de los retos actuales a nivel mundial es el reconocimiento de las personas a distancias importantes. Otro de los retos está en la etapa de extracción de características la cual representa un campo abierto de investigaciones por ser afectada en temas de oclusiones, deformaciones y localizaciones inexactas. En este trabajo de tesis se realiza un análisis de los métodos y de las características intrínsecas de la textura del iris para modelar una nueva representación de la información del iris que permita una robustez en el reconocimiento de personas a distancia bajo diferentes condiciones. Partiendo del análisis del estado del arte, se establece el enfoque del modelado de la textura del iris, el cual toma en cuenta las variaciones de intensidad y contraste en el iris ante los cambios de iluminación, como también la obtención de regiones distintivas de éste. La evaluación de los métodos de extracción de características conllevó a la selección del método con mayor desempeño ante cambios de iluminación. Con respecto a la extracción de regiones se usa un método que tiene en cuenta aproximaciones geométricas. La integración de los métodos generó el modelo propuesto de este trabajo de tesis el cual presenta un buen desempeño en el reconocimiento de personas bajo condiciones no controladas. El desempeño del modelo obtenido se compara con representaciones de único criterio y se evalúa con imágenes de iris adquiridas bajo diferentes condiciones.

Palabras claves: biometría, iris, reconocimiento, entorno no controlado, bases de datos.

Abstract

For more than two decades, the recognition based on the texture of the iris has been studied in various areas, social and industrial and had been developed biometric systems of recognition of people. The iris is one of the most reliable biometric features for the recognition of people. This is mainly due to its stability, its invariance in time and of course to the uniqueness of the texture patterns that are in the irises of the people. However, there are stages within the iris based recognition system that still require greater robustness, since one of the current challenges worldwide is the recognition of people at important distances. The feature extraction stage represents a challenge for recognition at distance and is an open field of research due to its being affected in terms of inaccurate occlusions, deformations and locations. In this work an analysis of the intrinsic characteristics of texture of iris and methods for represent texture of the iris was made. A new model of representation of the information of the iris was developed, that allows a robustness in the recognition of people at a distance under different conditions. Based on the analysis of the related bibliography, the iris texture modeling approach is established, which takes into account variations in intensity and contrast in the iris before changes in illumination, as well as the obtaining of distinctive regions of the iris. The evaluation of the methods of extraction of characteristics leads to the selection of the method with greater performance in light changes. Regarding the extraction of regions, a method that takes into account geometric approximations is used. The integration of the methods generated the proposed model of this thesis work which presents a good performance in the recognition of people under uncontrolled conditions. The performance of the obtained model is compared with representations of single criterion and is evaluated with iris images acquired under different conditions.

Key words: biometrics, iris, recognition, uncontrolled environment, databases.

Productos obtenidos

Artículos en congresos internacionales

- Montoya Obeso, L. A. Oropesa, Fernando Luis V., Cocolán Sara I., Stoian. Andrei, García Mireya S., Zamudio Luis M, Montiel Jesús Y., de la O Torres Saul, Ramírez Alejandro A., “Annotations of Mexican bullfighting videos for semantic index”. Optics and Photonics for Information Processing IX, 2015, vol. 9598, pp. 959815-959815–14.
- L. A. Oropesa, Montoya Abraham, Hernández Rosaura, Cocolán Sara I., García Mireya S., Benois-Pineau Jenny, Zamudio Luis M., Martínez Jesús A., Ramírez Alejandro A., “Video annotations of Mexican nature in a collaborative environment”. Optics and Photonics for Information Processing IX, 2015, vol. 9598, pp. 959811-959811–12.
- L. A. Oropesa, Maldonado Luis, Soto Andrea, García Mireya, Zamudio Luis M., Rodríguez Manuel A., Pérez Osvaldo G., Rodríguez Luis, Montoya Abraham, Ramírez Alejandro Á., “Technical issues for the eye image database creation at distance”. Optics and Photonics for Information Processing X, 99700E, 2016, vol. 9970, p. 99700E–99700E–7.

Presentaciones

- L. A. Oropesa. “Sistema Biométrico de Video iris e Indexación Multimedia”. Expositor en evento Descubre tu Posgrado. Centro de Investigación y Desarrollo de Tecnología Digital. Mayo, 2015.
- L. A. Oropesa, Montoya Obeso, García Vázquez. Mireya Saraí. “Uso del video para la identificación de personas y descripción de contenidos multimedia”. Expositor en Congreso nacional de las tecnologías de la información y comunicaciones. Instituto Tecnológico de Tijuana. Mayo, 2015.
- L. A. Oropesa, Montoya Obeso, García Vázquez. Mireya Saraí, Eduardo. Garea-Llano. “Proyectos aplicados: Sistema de reconocimiento biométrico y multimedia”. Universidad Autónoma de Baja California, Valle de las Palmas. Mayo, 2015.
- L. A. Oropesa. “Técnicas avanzadas de procesado de imagen, introducción a la biometría”. Expositor en Seminario de Otoño sobre Sistemas Digitales. Universidad Autónoma de Baja California. Octubre, 2016.
- L. A. Oropesa. “Técnicas avanzadas de procesado de imagen, introducción a la biometría”. Expositor en Seminario de Otoño sobre Sistemas Digitales. Centro de Nanociencias y Nanotecnología. UNAM. Ensenada. Noviembre, 2016.

ÍNDICE

Resumen	v
Abstract.....	vi
Productos obtenidos.....	vii
ÍNDICE.....	viii
Lista de Figuras	xi
Lista de Tablas.....	xii
Glosario de Términos	xiii
1 Introducción.....	1
1.1 Representación de la textura del iris en un sistema biométrico.....	1
1.2 Objetivo	5
1.2.1 Objetivos específicos.....	5
1.3 Enfoque del trabajo de tesis.....	6
2 Modelado de la textura del iris	9
2.1 Textura del iris.....	9
2.2 Enfoques de modelado de la textura del iris.....	9
2.3 Características de textura.....	14
2.3.1 Patrón local binario.....	14
2.3.2 LBP U2	17
2.3.3 CLBP	17
2.3.4 GLCM.....	18
2.4 Extracción de regiones	19
2.4.1 Snakes.....	20
2.4.2 Modelos geométricos de contornos activos.....	22
2.4.3 Propiedades de las regiones.....	24

2.5	Desempeño de extracción de características de textura.....	26
2.5.1	Métodos evaluados	26
2.5.1	Metodología de evaluación.....	27
2.5.2	Bases de datos de textura.....	28
2.5.3	Resultados.....	29
2.6	Conclusiones.....	30
3	Modelo propuesto de representación de la textura del iris	32
3.1	Criterio parte 1. Comparación de características de textura.....	33
3.1.1	Delimitar bloques	33
3.1.2	Características LBP	34
3.1.3	Distancia Euclidiana	34
3.1.4	Comparación por bloques.....	35
3.2	Criterio parte 2. Comparación de formas geométricas	35
3.2.1	Obtención de regiones	36
3.2.2	Índice J.....	37
3.2.3	Comparación.....	39
3.3	Modelo propuesto	39
4	Bases de datos.....	42
4.1	UPOL.....	42
4.1	UBIRIS	42
4.2	MBGC	43
4.3	Comparativa de condiciones de captura	44
5	Esquema de evaluación del modelo propuesto.....	45
5.1	Grafica de distribución genuinas e impostoras.....	45
5.2	Curvas características	46

5.3 EER (<i>Equal Error Rate</i>) e índice decisión (<i>d-index</i>)	48
5.4 Metodología de comparación. Parte uno del modelo propuesto.	49
5.5 Metodología de comparación. Parte dos del modelo propuesto.	51
5.6 Metodología de comparación del modelo.	54
6 Resultados experimentales	57
6.1 Análisis de resultados parte uno del modelo	57
6.2 Análisis de resultados parte dos del modelo.....	58
6.3 Resultados del modelo propuesto.....	60
6.4 Conclusiones.....	66
7 Conclusión general	68
7.1 Contribuciones del trabajo de tesis.....	70
7.2 Trabajo Futuro	71
7.3 Seguimiento y mejoras	71
Anexos	73
Anexo 1	73
Anexo 2.	75
Anexo 3	76
Anexo 4	77
Referencias	79

Lista de Figuras

Figura 1. Marco de trabajo.....	6
Figura 2. Iris del ojo.	9
Figura 3. Representación multi-escala de (Fuente: Wildes).	11
Figura 4. Cálculo de LBP (Fuente: Bikramjot).	15
Figura 5. Vecindad de píxeles (Fuente: H.R.E Doost).	15
Figura 6. Texturas y su histograma luego del operador LBP.	16
Figura 7. Histograma de objetos con valores iguales.	16
Figura 8. Patrones uniformes. (Fuente: Ojala).....	17
Figura 9. Cálculo de CLBP_Sign y CLBP_Mag (Fuente: D. Zang). (a) Muestra local 3x3, (b) diferencias locales, (c) signo de diferencias, (d) la magnitud.	18
Figura 10. Cálculo de la matriz en dirección horizontal a un píxel de distancia. (Fuente: Mathworks).....	18
Figura 11. Puntos del Snake.	21
Figura 12. Segmentación ROF+CA. a) Imagen ruidosa con contornos interiores, b) segmentación de la imagen ruidosa con los contornos interiores (Fuente: Bresson). c) objeto irregular, d) segmentación del objeto irregular.	23
Figura 13. Conectividad de píxeles a) cuatro conectividad, b) ocho conectividad.....	25
Figura 14. Base de datos Broadtz (Fuente: Phil Broadtz).	28
Figura 15. Base de datos Marmi (Fuente: A. Fernández).	28
Figura 16. Primer criterio de reconocimiento.	33
Figura 17. División de la textura del iris.	33
Figura 18. Procesamiento LBP.	34
Figura 19. Segundo criterio de reconocimiento.....	36
Figura 20. Resultado de la segmentación de las regiones.....	36
Figura 21. Ejemplo de intersección y unión de conjuntos.....	37
Figura 22. Diferentes valores de Jacc para diferentes ejemplos de las formas:	38
Figura 23. Descripción del modelo propuesto.	40
Figura 24. Base de datos UPOL.....	42
Figura 25. Imágenes base datos UBIRIS.	43
Figura 26. Gráficas de los resultados de comparación.....	45
Figura 27. Curvas ROC de cada método de clasificación (líneas de color) evaluado.....	47
Figura 28. Distribuciones de comparaciones con tasa de igualdad de error (EER).....	48
Figura 29. Reducción de tamaño de bloques.....	56
Figura 30. Comparaciones MBGC-C30S5.....	57
Figura 31. Distribución de las comparaciones experimento 1.....	59

<i>Figura 32. Resultado de las segmentaciones.....</i>	<i>60</i>
<i>Figura 33. Curva ROC comparaciones de métodos en base de datos MBGC C30M5.</i>	<i>62</i>
<i>Figura 34. Curva ROC comparaciones de métodos en base de datos MBGC C100M20.</i>	<i>63</i>
<i>Figura 35. Curva ROC comparaciones de métodos en base de datos Ubirisv1.....</i>	<i>64</i>
<i>Figura 36. Curva ROC comparaciones de métodos en base de datos UPOL.....</i>	<i>65</i>
<i>Figura 37. Resultado reducción de bloques.....</i>	<i>66</i>
<i>Figura 38. Imagen de ejemplo para algoritmo SIFT.</i>	<i>73</i>
<i>Figura 39. Diferencias gaussianas (DoG).....</i>	<i>74</i>
<i>Figura 40. Puntos detectados del algoritmo SIFT.</i>	<i>74</i>
<i>Figura 41. Región cercana a la característica detectada.....</i>	<i>75</i>
<i>Figura 42. Distribuciones genuinas e impostoras base de datos UPOL.</i>	<i>77</i>
<i>Figura 43. Distribuciones genuinas e impostoras en la base de datos MBGC de 30 personas.</i>	<i>77</i>
<i>Figura 44. Distribuciones genuinas e impostoras en base de datos MBGC de 100 personas.....</i>	<i>78</i>
<i>Figura 45. Distribuciones genuinas e impostoras en base de datos Ubiris.....</i>	<i>78</i>

Lista de Tablas

<i>Tabla 1. Propiedades de matriz de co-ocurrencia (Fuente: Mathworks).....</i>	<i>19</i>
<i>Tabla 2. Parámetros de métodos y espacio de búsqueda.</i>	<i>27</i>
<i>Tabla 3. Propiedades de las bases de datos.</i>	<i>29</i>
<i>Tabla 4. Base de datos Mondial Marmi.....</i>	<i>29</i>
<i>Tabla 5. Base de datos Brodatz.</i>	<i>29</i>
<i>Tabla 6. Base de datos comparativa.</i>	<i>44</i>
<i>Tabla 7. Cantidad de comparaciones.</i>	<i>50</i>
<i>Tabla 8. Descripción de los experimentos.....</i>	<i>52</i>
<i>Tabla 9. Parámetros de modelo de Bresson.</i>	<i>53</i>
<i>Tabla 10. Las 3 segmentaciones de dos imágenes diferentes de la misma clase.....</i>	<i>53</i>
<i>Tabla 11. Las 3 segmentaciones de 2 imágenes de clases diferentes.</i>	<i>54</i>
<i>Tabla 12. Experimentos en diferentes bases de datos.....</i>	<i>55</i>
<i>Tabla 13. Resultado de las comparaciones.</i>	<i>58</i>
<i>Tabla 14. Resultado del modelo propuesto.....</i>	<i>61</i>
<i>Tabla 15. Segmentación requerida en evaluaciones.....</i>	<i>76</i>
<i>Tabla 16. Segmentaciones descartadas en evaluaciones.....</i>	<i>76</i>

Glosario de Términos

SRI	Sistemas de Reconocimiento de Iris
Plantilla	Imagen que representa en coordenadas rectangulares el iris de una persona
Clase	Se refiere a la persona o a las muestras de iris de la persona.
Intra clase	Comparar plantillas de la misma persona. Comparación genuina.
Inter clase	Comparar plantillas de diferentes personas. Comparación impostor.
MBGC	Base de dato de reto biométrico (<i>Multiple Biometric Grand Challenge</i>)
GAC	Contornos activos geodésico o geométrico (<i>Geodesic/Geometric Active Contorn</i>)
ROF	Modelo Rubi y Fatermi de reducción de ruido (<i>Rubi and Fatermi</i>)
UPOL	Base de dato UPOL (<i>University of "Palack'eho and Olomouc</i>)
UBIRIS	Base de datos UBIRIS (<i>A Noisy Iris Image Database</i>)
FFT	Transformada rápida de Fourier (<i>Fast Fourier Transform</i>)
DCT	Transformada discreta del coseno (<i>Discrete Cosine Transform</i>)
GLCM	Matrices de niveles de intensidad (<i>Gray Level Co-ocurrence Matrix</i>)
EER	Índice de igualdad de error (<i>Equal Error Rate</i>)
FAR	Tasa de falsa aceptación (<i>False Acceptance Rate</i>)
FRR	Tasa de falso rechazo (<i>False Reject Rate</i>)

1 Introducción

1.1 Representación de la textura del iris en un sistema biométrico

La biometría es un campo de estudio dedicado al reconocimiento automático de personas basado en sus características físicas o de comportamiento [1]. La ventaja de utilizar biometría es que con los sistemas de reconocimiento biométricos no se necesita recordar claves o tener tarjetas de identificación para acceder a determinado lugar o servicio. Esta ha sido aplicada en diversos sistemas para controlar el acceso a lugares con áreas restringidas, verificación de presencia de individuos e identificación y verificación de personas. Los sistemas biométricos se han implementado utilizando rasgos únicos de las personas como son: el rostro, huella, retina, iris, forma de caminar, hablar de las personas, entre otros [2]. El estudio de la biometría y los sistemas biométricos abarca diferentes áreas de conocimiento como son: procesamiento de imágenes, reconocimiento de patrones, clasificación, aprendizaje de máquinas [3], entre otros. Uno de los rasgos biométricos más precisos es el iris por el alto nivel de aleatoriedad del patrón del iris de las personas [4]. Utilizar el iris como identificador biométrico tiene la ventaja de que no se necesita que la persona esté en contacto físico con algún dispositivo cuando se realiza la captura de las imágenes de ojos [5]. Los iris de las personas son diferentes y únicos en ambos ojos aun cuando este sea adquirido de gemelos idénticos, además de mantener su forma a través del tiempo [6]. La unicidad del patrón del iris proviene de sus detalles de textura como criptas, surcos, surcos radiales, los cuales conforman los micro detalles de textura de los patrones distintivos de los iris de las personas [7], [8]. La distribución aleatoria de los micro detalles de textura componen los rasgos distintivos del iris [9].

En la actualidad son perceptibles los sistemas que hacen uso de la biometría del iris, entre ellos podemos mencionar EyeCash [10], el cuál es el primer sistema de reconocimiento biométrico de iris para aplicación en cajeros automáticos. Se ha implementado además un sistema de reconocimiento de iris en dispositivos móviles como es el caso de Samsung Galaxy Note 7 [11]. En las últimas décadas el reconocimiento de iris ha alcanzado gran popularidad y se ha visto un crecimiento en el mercado de acuerdo a un reporte realizado por analistas de TechNavio [12]. El primer algoritmo de reconocimiento de iris fue propuesto por John Daugman y estableció una patente [13], [14]. El algoritmo de Daugman ha sido utilizado en productos de reconocimiento de iris comerciales como el distribuido por Iridian Technologies [15]. Otro de

los primeros productos que se ha realizado bajo este algoritmo es el distribuido por LG IRIS el cuál utilizó el dispositivo *IrisAccess 2200* en el año 1999 y posteriormente el dispositivos *IrisAccess 3000* en el año 2001 [16]. En la actualidad está disponible el *iCAM4000* [17], que sustituye las versiones anteriores de *IrisAccess*. El método implementado para reconocer los iris de las personas por Daugman es confiable y ha sido utilizado en controles de acceso [18], documento nacional de identidad, cruces de fronteras [19], aeropuertos [20], entre otras aplicaciones. Para lograr el reconocimiento de las personas Dugman realiza el procesamiento de imágenes de ojos por etapas. Entre las etapas está la adquisición de imágenes de ojos, segmentación de la región de la textura del iris, extracción de características distintivas y comparación de iris de las personas.

La etapa de “adquisición” se refiere a los diferentes pasos donde se captura una imagen de ojos de las personas. En esta etapa se tienen en cuenta elementos de hardware como tarjetas de adquisición y sensores para adquirir imágenes de ojos con buena calidad. Elementos de software de procesamiento de imágenes son necesarios también en esta etapa para detectar presencia de ojos en las imágenes adquiridas [21].

La etapa de “Pre-procesamiento” es donde se detecta la información útil(iris) de la información no útil (pupila, parpados, pestañas) que puede conducir a un bajo rendimiento de todo el proceso de reconocimiento. La textura del iris es separada de otras regiones no deseadas lo cual es un paso crucial para el correcto reconocimiento. Después se transforma la textura del iris a un espacio rectangular para facilitar el procesamiento en las etapas posteriores [21].

La “Extracción de características” es otra etapa donde lo importante es obtener una representación de los rasgos discriminativos del iris. En esta etapa además se han utilizado métodos de codificación para una representación más compacta de la información única. Finalmente la etapa de “Comparación” donde las características de iris extraídas son comparadas [21].

Aun cuando el principal objetivo de cada etapa es mejorar el desempeño en el reconocimiento total del sistema de reconocimiento, la etapa de extracción de características juega un rol importante. Ha sido probado que la textura del iris permite la identificación de las personas, pero no siempre la textura está completamente representada en la etapa de extracción de características o posee variaciones entre las muestras obtenidas de una misma persona [22]. La falta de información de textura visible del iris por obstrucción de parpados o pestañas, reflejos

de luz, fuera de ángulo o diferentes tipos de ruido son condiciones que pudieran estar presentes en esta etapa. Aun cuando se han realizado capturas a distancias con mejores cámaras y con mayor volumen de captura¹ estas condiciones están presentes [21]. Poder identificar las personas a distancias considerables (más de un metro) agrega complejidad en el reconocimiento [23]. A más de un metro las condiciones mencionadas se hacen presente y en un área de textura se tienen variaciones no uniformes de la distribución espacial en intensidad o color lo que incurre en mayor variabilidad. Los sistemas tradicionales como el de Daugman han sido implementados en entornos de captura a corta distancia y con un volumen de captura pequeño lo que requiere una activa participación del usuario para realizar la adquisición de las imágenes de ojos. En un poco más de dos décadas muchos trabajos han surgido con el objetivo de mejorar el desempeño del reconocimiento de estos sistemas [22], [24]–[44]. Con el fin de mejorar el reconocimiento en la etapa de extracción de características Wildes [24], plantea una representación multi-escala del iris, de manera que una gama más amplia de detalle espacial pueda ser capturado para representar las características distintivas en la textura del iris. Para ello utilizó filtros que representaban las variaciones en la textura del iris. El método de Ma et al. [27], por otra parte realiza los detalles de textura en imágenes de iris realizando una estimación de la iluminación del fondo de la textura. Se utiliza un método para ecualizar el histograma mejorando así el contraste de la textura del iris. Posteriormente es aplicado un filtro espacial que provee información en la imagen en una orientación sobre una región de interés del 75% que incluye más información de textura de iris cercana a la pupila. Debido a que en la zona más cercana a la pupila existe poca probabilidad de presencia de parpados o pestañas se ha logrado mejorar el desempeño en la etapa de extracción de características [27]. Por otra parte Ko et al. [34], en el año 2007 planteó un método de extracción de características de iris basados en sumas acumulativas analizando los cambios de niveles de grises en imágenes de iris. Dividieron la textura del iris en regiones las cuales llamaron celdas de tamaño $m \times n$, para cada celda calcularon las sumas acumulativas de los niveles de grises para la representación de las características distintivas de la textura. En el trabajo de Ko, al igual que en trabajo de Ma, se realizó un realce de características de textura que permitió mejorar el contraste utilizando un método de ecualización de histogramas [34]. En el trabajo de Monro [33], a diferencia de Ko,

¹ Espacio disponible para capturar las imágenes de ojos. Puede verse como un cubo en 3D en la sala donde es viable obtener las imágenes de ojos.

donde realizaron división en celadas, las características fueron extraídas en regiones que le llaman parches [33]. Los parches pueden superponerse y se utilizó la DCT (Transformada Discreta del Coseno) en cada parche para extraer las características debido a la propiedad de compactación de energías y que esta puede ser obtenida de una forma rápida.

La cuestión más difícil en la etapa de extracción de las características de la textura del iris es lograr mayor sensibilidad a las diferencias entre imágenes de ojos de diferentes personas y al mismo tiempo mantener la robustez con las variaciones de imágenes de ojos de una misma persona. Aunque hay un estándar definido para el intercambio de datos de imágenes de la textura de un iris [45], no se menciona cómo extraer o representar las características distintivas con propósitos de comparación. Por tal motivo se necesitan mejores métodos que permitan extraer de forma eficiente las características de la textura del iris, que sean robustos y discriminativo en las comparaciones bajo diferentes condiciones. Una posible vía para mejorar la etapa de extracción de características es poder obtener y describir las regiones más distintivas que se encuentran en la textura de un iris para una mejor representación.

En la literatura, la mayoría de los métodos se basan en utilizar un criterio de extracción de características para comparar imágenes de iris de las personas. La utilización de sólo un método de extracción de características origina que el desempeño del reconocimiento esté limitado al método utilizado. Mediante una revisión de la bibliografía podemos ver que no existen métodos que permitan obtener las formas geométricas distintivas en la textura de un iris para poder comparar y hacer el reconocimiento. Aunque existen métodos para comparar iris a partir de varios métodos de extracción de características ninguno utiliza la información de las regiones geométricas de la textura del iris [46], [47].

Basándonos en la problemática anterior, la propuesta en el trabajo de tesis es obtener una nueva representación de la textura del iris de las personas extrayendo las regiones geométricas para mejorar la robustez. Se desean reconocer las formas geométricas que son representativas dentro de la textura de iris y luego compararlas. Si se modelizan las formas utilizando aproximaciones geométricas y luego se describen las características de textura, entonces se pueden utilizar en reconocer personas. Las regiones geométricas obtenidas en el iris deben estar localizadas y deben repetirse en los iris de las personas. Si las regiones se obtienen sin importar que exista ruido causado por las condiciones de captura y permanecen en texturas de iris iguales entonces pudiera mejorar el desempeño en la etapa de extracción de características. Si además de extraer

las regiones geométricas representativas se obtiene otro criterio que ayude a mejorar el desempeño cuando exista poco contraste debido a las diferentes condiciones de iluminación entonces el desempeño puede ser más robusto bajo diferentes condiciones.

Se propone investigar en una nueva representación de la información discriminante del iris la cual puede estar compuesta de varios métodos de extracción de características y que utilice criterios totalmente diferentes para la comparación. Si se modelizan las estructuras que están presente en los iris mediante formas utilizando aproximaciones geométricas, y luego se describen las características de textura, entonces se pueden utilizar en reconocer personas. Se debe poder extraer información de las regiones geométricas representativas dentro de la textura de un iris, aunque exista ruido y compararlas. Otra cuestión pudiera considerar extraer información de la textura del iris teniendo en cuenta aspectos invariantes a contrastes o iluminación. Para la combinación de métodos y representación de la textura final se puede definir algún modelo que permita unificar más de un método de extracción de características. Se debe verificar la tasa de reconocimiento cuando utilizamos sólo un criterio de extracción de características y comparar con otros algoritmos analizados en la literatura basado en único criterio.

Con el fin de obtener una nueva representación del iris de las personas extrayendo las regiones geométricas y la información de la textura del iris para mejorar la robustez se plantea el siguiente objetivo:

1.2 Objetivo

Obtener un modelo de estructuras espectrales de iris basado en aproximaciones geométricas.

1.2.1 Objetivos específicos

1. Estudiar el estado del arte sobre los modelos biométricos de reconocimiento de iris.
2. Profundizar el estudio de la bibliografía en los métodos de extracción de características utilizados para el reconocimiento de iris.
3. Analizar métodos que permitan extraer información de las estructuras geométricas del iris.
4. Analizar métodos para describir características de textura.
5. Analizar métodos para extraer formas geométricas en el iris.
6. Implementar métodos de extracción de características de textura en iris.

7. Implementar métodos de extracción de formas geométricas en iris.
8. Adquirir imágenes espectrales de iris.
9. Analizar medidas para evaluar los algoritmos de comparación en el reconocimiento de iris.
10. Proponer un nuevo modelo de representación de textura de iris.
11. Validar el modelo propuesto y comparar con los algoritmos analizados en el estado del arte.

1.3 Enfoque del trabajo de tesis

El enfoque del trabajo de tesis estará centrado hacia el desarrollo de operaciones y técnicas computacionales para tener una nueva representación de la textura del iris en la etapa de extracción de características. Se puede observar en la Figura 1 un esquema con las diferentes etapas de reconocimiento en la cual está delimitada en color rojo la etapa de interés de este trabajo. Dentro de las etapas de reconocimientos descritas en la Figura 1, se propone hacer uso de elementos de etapas anteriores y posteriores a la extracción de características.

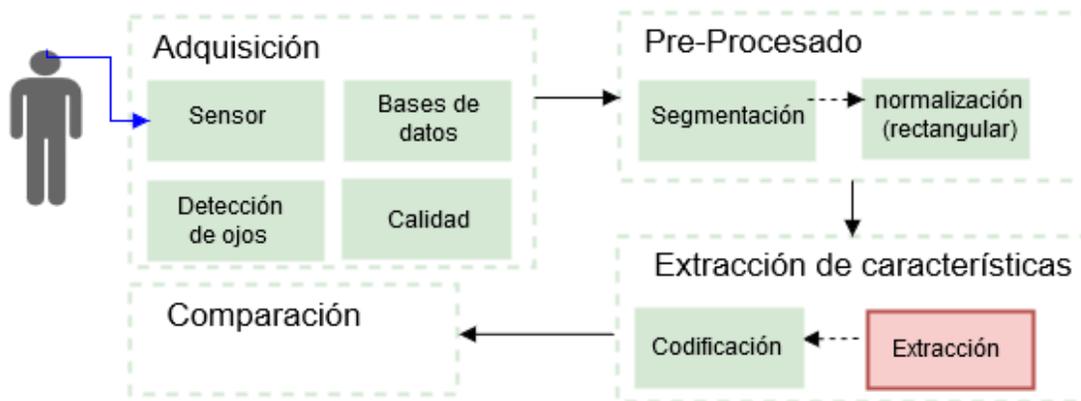


Figura 1. Marco de trabajo.

Para una mejor comprensión del trabajo y dar cumplimiento a los objetivos propuestos se organizó la escritura por capítulos:

En el **capítulo 2** se definen los elementos que componen la textura del iris. Los diferentes modelos de reconocimientos de la literatura que utilizan la textura del iris como identificador biométrico son analizados. Es analizado además el funcionamiento de los modelos de representación de la textura del iris y el enfoque más detallado está en la etapa de extracción de

características. En este capítulo es mostrada una breve descripción en orden cronológico de otras técnicas de reconocimiento propuestas recientemente. Los modelos de representación analizados en la revisión de la literatura nos ayudan a entender las diferentes técnicas utilizadas para reconocer personas por medio de la información de la textura del iris. Servirán como base para comprender el funcionamiento de los sistemas, retomar puntos fuertes y proponer mejoras. Se describen los métodos de texturas y de extracción de formas geométricas que van a permitir extraer las características distintivas que conformarán el modelo propuesto. Finalmente se realizan experimentos en bases de datos de textura para evaluar métodos de extracción de características de textura y obtener los métodos más discriminativos.

En el **capítulo 3** se explica el modelo propuesto para representar la textura del iris. Para la conformación del modelo final se retomaron los métodos que dieron buenos resultados en la extracción de características y que fueron evaluados en la clasificación con bases de datos de texturas. Además, se tuvieron en cuenta algunas ventajas de métodos analizados anteriormente en la literatura. Se describe la representación de las regiones geométricas y se explican los criterios de comparación en los que se compone el modelo. Finalmente son explicadas las dos partes que conforman el modelo. La utilización de los métodos de extracción de características para componer el modelo, la segmentación de las regiones y los criterios de comparación por bloques son descritos en este capítulo. El modelo se presenta utilizando ecuaciones matemáticas y en forma gráfica, así como sus principales parámetros.

En el **capítulo 4** se describen las bases de datos utilizadas para los experimentos. Es analizado las condiciones y el entorno de captura de cada base de datos de iris para la evaluación. Una comparativa de las condiciones de los factores de ruido de cada base de datos es obtenida luego de analizar las características de cada base de datos.

En el **capítulo 5** se propone un esquema de evaluación utilizando métodos de evaluación numéricos y gráficos. Los métodos se basaron en índices de decisión, errores y curvas gráficas para medir el reconocimiento de los diferentes criterios del modelo propuesto. Se propone una metodología basada en experimentos utilizando bases de datos de texturas de iris para evaluar las partes del modelo. Posteriormente se utiliza una metodología para evaluar todo el modelo

propuesto combinando ambas partes del modelo. Los parámetros de los métodos y sus valores se describen en cada metodología de evaluación.

En el **capítulo 6** son descritos los resultados de los experimentos propuestos para cada metodología descrita en el capítulo anterior. El desempeño del modelo propuesto es validado utilizando bases de datos con métricas numéricas y gráficas previamente analizadas. Los resultados obtenidos son posteriormente comparados con el desempeño de diferentes modelos de reconocimiento basados en único criterio analizados en el estado del arte. Se realiza un análisis de los resultados de cada parte del modelo utilizando el modelo final. Finalmente es verificada la robustez del modelo haciendo menos procesamiento y verificando el reconocimiento.

En el **capítulo 7** se presentan las conclusiones generales del trabajo, análisis del trabajo futuro. Es descrito además otras ideas para el seguimiento del trabajo y mejoras que podrían realizarse a las diferentes partes del modelo.

2 Modelado de la textura del iris

2.1 Textura del iris

El iris es una estructura en forma de anillo de tejido conectivo elástico que forma un patrón de textura aleatoria [7]. Se ubica en la parte coloreada del ojo más cercana a la pupila. La pupila es el agujero centrado en el centro del iris (ver Figura 2) de color negro de forma circular que regula la cantidad de luz que entra en el ojo [9]. La Figura 2 muestra una imagen muy cercana del iris donde se puede observar la pupila y la estructura de la textura del iris.

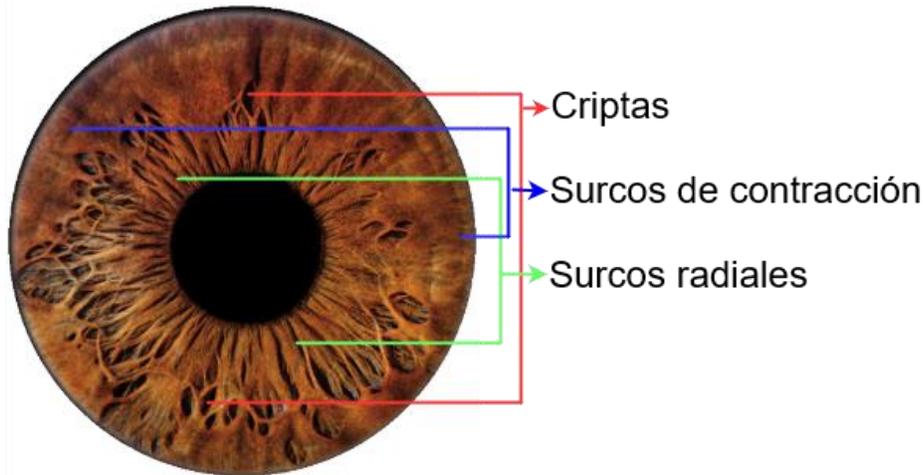


Figura 2. Iris del ojo.

La superficie del iris consiste de varias capas y se caracteriza por surcos radiales de contracción y criptas [7] (ver Figura 2). En la Figura 2 se puede observar las diferencias de formas en las criptas y surcos los cuales son nombrados “micro detalles” de la textura de iris, [8], [9]. Los micro detalles también pueden estar compuestos por puntos pigmentados [8]. La composición de la textura del iris es diferente entre personas aun en el caso de gemelos idénticos y diferente además en los ojos izquierdo y derecho de una misma persona [6].

2.2 Enfoques de modelado de la textura del iris

Las investigaciones en el reconocimiento de iris han atraído a muchos investigadores a proponer novedosos métodos para tal fin. Por consiguiente, muchos enfoques han sido desarrollados para el reconocimiento de iris propuestos en la literatura. Los trabajos analizados en la literatura tienen sus principales aportes en las etapas de adquisición y pre procesamiento [21] (ver cf.

Sección 1.1) pero la mayoría de las técnicas disponibles para modelar la textura del iris utilizan la etapa de extracción de características (ver cf. Sección 1.1) [21].

Para modelar la textura de un iris se han utilizado varios enfoques. Daugman [13] fue el primero en proponer un algoritmo de reconocimiento de iris en 1993. En su trabajo aplicó un operador integro-diferencial para extraer la porción del iris en imágenes de ojos. Posteriormente la textura visible del iris de una persona fue modelada con una secuencia compacta utilizando filtros de Gabor en dos dimensiones (2D). Al utilizar los filtros de Gabor se obtiene una representación de la textura del iris debido a que se extrae información en espacio y frecuencia. Las características extraídas dependen de la cantidad de filtros aplicados cuando se varían las orientaciones y la frecuencia, esto un proceso que tarda debido a la aplicación de diferentes filtros. El resultado luego de codificar la respuesta es un código de iris (*IrisCode*) de 2048 bits ocupando 256 bytes. En el proceso de comparación la distancia de Hamming fue utilizada para comparar la codificación de los iris [13].

En otro modelo de representación de textura de iris Masek [42], aplicó una implementación de filtros de Gabor pero en escala logarítmicas sobre una señal en una dimensión (1D) de la textura del iris. El modelo de Masek se basó en que los filtros de Gabor en escala logarítmica (*LogGabor*) son una mejora en comparación con los filtros de Gabor propuestos por Daugman y mejor se adaptan los cambios de intensidades en las imágenes. En este modelo cada fila de la textura normalizada del iris lo cual corresponde a un anillo de la región del iris en forma rectangular es tomado como una señal de una dimensión (1D). Para evitar efectos de ruido en el filtro, los valores de cada fila en la plantilla fueron promediados con los de sus filas vecinas antes de aplicar el filtro. El filtro en escala logarítmica fue aplicado en cada una de las filas de la plantilla y fue codificado usando el mismo método de Daugman [42].

En otro modelo a diferencia del modelo de Daugman y Masek, Wildes [24], utilizó un proceso de alineación espacial con dos texturas de iris. Se plantean dos pasos sin aplicar filtros de Gabor para reconocer después de alinear las texturas del iris:

1. Selección de la representación que maximice los patrones distintivos en las texturas
2. Determinar la similitud entre dos iris

En el primer paso considera la ventaja de una representación multi-escala de manera que una gama más amplia de detalle espacial pueda ser capturado en la textura del iris. Para realizar este

proceso realizaron una descomposición de paso banda utilizando un filtro laplaciano (*Laplacian of Gaussian*) [24]:

$$\nabla G = \frac{1}{\pi\sigma^4} \left(1 - \frac{\rho^2}{2\sigma^2}\right) e^{-\frac{\rho^2}{2\sigma^2}} \quad [24] \quad (2-1)$$

Donde σ es una desviación estándar de la función Gaussiana y ρ es una distancia radial al centro del filtro. La representación en forma de pirámide de la Figura 3 [24] es el resultado de aplicar el modelo de Wildes, el cual es capaz de comprimir los datos tal que sólo los significativos permanecen. La pirámide fue construida con cuatro niveles de resolución para generar una representación más compacta (ver Figura 3).

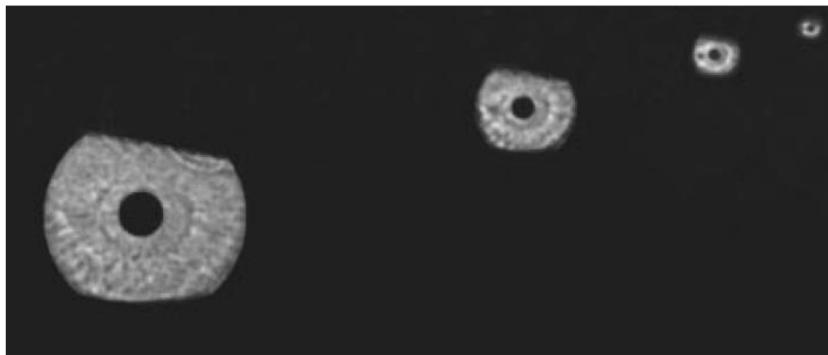


Figura 3. Representación multi-escala de (Fuente: Wildes).

Para determinar la similitud entre las nuevas representaciones de las texturas de iris se utilizó una correlación con una ventana de tamaño 8 x 8 para cada una de las cuatro bandas de la pirámide.

El modelo de Ma et al. [27], para realzar los detalles de textura se estimó la iluminación de fondo. La iluminación estimada es luego sustraída a la normalización de textura rectangular para compensar la variedad de luz. En el trabajo de Ma utilizan un método para ecualizar el histograma mejorando así el contraste. Las variaciones locales en bloques de textura rectangular fueron tenidas en cuenta para extraer características y distinguir entre dos iris. Definen un filtro espacial que sólo provee información en la imagen a cierta orientación a diferencia del filtro de Gabor que se utiliza en diferentes escalas y orientaciones. El filtro es aplicado en una región de interés dividida en bloques que abarcan el 75% de la textura del iris cercana a la pupila. A cada bloque se le extrae información de su media y su varianza para un total de 1536 características que conforman el vector final de características 1D. En sus experimentos reflejan que la región

más cercana al borde de la pupila contiene más información discriminante debido a que los párpados y pestañas raramente están presentes en esas localizaciones [27].

En otro trabajo para modelar la textura de un iris Ko et al. [34], en el año 2007 planteó un método de extracción de características basados en sumas acumulativas analizando los cambios de grises en imágenes de iris. Para ello dividieron la textura del iris en regiones que le llaman celdas, de tamaño $m \times n$. Para cada celda calcularon las sumas acumulativas de los niveles de grises. Luego el código de iris fue generado analizando los cambios en los valores de los patrones de las sumas acumulativas. Antes de calcular las sumas acumulativas primero utilizaron un realce basado en ecualización del histograma que permitió mejorar el contraste en la textura del iris [34].

Monro [33], presentó para la representación de características de la textura un novedoso sistema de codificación de iris basado en diferencias de la transformada discreta del coseno. Utilizaron la DCT (Transformada Discreta del Coseno) debido a la propiedad de compactación de energías y que esta puede ser obtenida de una forma rápida. Para extraer las características discriminativas a partir de una plantilla normalizada del iris, la textura se divide en regiones que le llaman parches. Los parches pueden superponerse y son extraídos de las primeras 48 filas del total de 80 más cercanas a la pupila para evitar efectos de oclusión por pestañas. Cada parche conforma un sub conjunto de características que son extraídas a partir de los coeficientes de la DCT. Antes de aplicar la DCT primero se promediaron los valores de intensidad de cada parche en su dirección horizontal para obtener una señal en una dimensión (1D). El promedio de valores de intensidad ayudó a suavizar los datos y eliminar efectos de ruido. Luego las diferencias en los valores de la DCT de parches adyacentes son calculadas y se conforma el vector binario de características a partir de obtener los cruces con cero de las diferencias. Como las características extraídas conforman un vector binario final, estas pueden ser comparadas a partir de distancia de Hamming. El modelo de Monro [33], supera su trabajo similar de extraer las características en cada parche utilizando la FFT (*Fast Fourier Transform*) [29].

En la actualidad se han propuesto recientes métodos para extraer características de la región del iris. Los métodos utilizados permiten representar las diferencias de los valores de intensidad de la textura de un iris. Uno de los métodos utilizados y que permite detectar características en diferentes puntos de la textura es el algoritmo SIFT (*Scale Invariant Feature Transform*) [32] [43] [39]. Zhu et al. [32], presentó extracción de características para reconocer textura de iris para

problemas como localización inexacta, oclusión utilizando este algoritmo. El algoritmo SIFT permite obtener puntos que se detectan en intensidades claras y oscuras en la imagen que presentan ciertas propiedades (ver Anexo 1). Se utiliza el anillo de la textura del iris sin mejoras para la extracción de características. Esto reduce la etapa de “pre procesamiento”(ver Sección 1.1) de iris, sin embargo, los resultados experimentales de su trabajo muestran que las informaciones extraídas de la textura no se pueden representar bien sin una imagen realzada. Esto se debe a que micro detalles de la textura de las imágenes de iris tienden a ser ignoradas. G. Yang et al. [43], también utilizaron el algoritmo SIFT para el reconocimiento de iris. Ellos demuestran que, aunque el algoritmo SIFT es invariante a las imágenes en escala y rotación, en la práctica es necesario utilizar la etapa de “pre procesamiento”(ver Sección 1.1) para normalizar y realzar la textura. La normalización resuelve dos problemas: diferentes escalas y diferentes ángulos de rotación de capturo de imágenes del iris. El realce por su parte permite conseguir en el modelado con SIFT los puntos de interés suficientes de la textura del iris. Aunque se ha demostrado que utilizar por sí solo el método SIFT no ofrece buenos resultados, éste si brinda buenos resultados en la fusión con otros algoritmos de extracción de características [39].

Otros de los métodos utilizados en representación de textura de iris son las matrices GLCM (Gray Level Co-ocurrence Matriz) [31], [37] y algoritmos basados en LBP (Patrones Locales Binarios) [44] [36] [41] para describir las características en todos los puntos de la textura del iris. Los algoritmos LBP se han utilizado con diferentes enfoques de reconocimiento. En el trabajo de Marciso, Nappi et al. [44]² combinan las características LBP con un descriptor de regiones claras y oscuras a través de bancos de filtros con operadores LoG (*Laplacian of Gaussian*) [36]. El operador LoG es efectivo como detector de contornos para representar los micro detalles de la textura del iris, pero es muy sensible a ruido. Para poder detectar las variaciones en la textura y resolver el problema de ruido se ha propuesto suavizar la imagen con filtros gaussianos a diferentes escalas con selección automática de la escala [36], [44]. M. Y. Shams et al. [41] desarrollaron un sistema biométrico el cual divide en bloques la textura del iris de una persona y le extrae las características LBP a cada división. Las características extraídas de cada bloque se representan usando el histograma LBP y son luego concatenadas

² Este trabajo obtuvo el sexto lugar en “*NICE.II iris biometrics competition*”
“<http://nice2.di.ubi.pt/>”

para formar el vector de características final. Z. Sun, T. Tan, y X. Qiu [30] también desarrollaron un algoritmo basado en división en bloques de la textura de un iris. Luego extraen las características usando el algoritmo LBP con los patrones uniformes y obtienen un vector de 59 dimensiones para cada bloque. Los bloques son luego comparados usando una representación por grafos. Las comparaciones locales usando LBP y la representación por grafos han demostrado ser eficientes para el reconocimiento [30]. Plantearon que no es necesario que toda la textura esté presente en el iris, solo una cierta cantidad de bloques en la textura del iris es suficiente para el reconocimiento. En otro trabajo se propone un esquema que utiliza información de una región local para criterios de decisión local y global [47]. Utilizan más de un criterio de extracción de características y lo combinan en un solo criterio para la comparación.

2.3 Características de textura

El iris presenta estructuras particulares abundantes en información de textura. Por tal motivo es deseable analizar los métodos que puedan representar la información de las variaciones de intensidad y contraste en la textura de un iris.

2.3.1 Patrón local binario

Los patrones locales binarios LBP [48], es un método eficiente usado en extracción de características de textura con motivos de clasificación, fue primeramente presentado por Ojala et al. [49] en 1996. En sus inicios fue introducido como una medida complementaria para información de contraste. Tiene la característica que es invariante a cambios de iluminación en los niveles de grises añadiendo información complementaria de la textura de la imagen. Es ideal para aplicaciones que requieren rápida extracción de características y clasificación de texturas. Puede ser visto como un enfoque unificador para los modelos estadísticos y estructurales de análisis de textura [48] cuya formulación base se ilustra en la siguiente formula:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p \quad (2-1)$$

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (2-2)$$

La variable g_p en (2-1) indica los vecinos al elemento central g_c en una ventana. Esta diferencia es luego cuantificada usando la función signo de (2-2) y multiplicada por 2^p a fin de obtener el patrón binario local. El valor P en (2-1) indica el número de vecinos alrededor del elemento central g_c del operador. El valor R en (2-1) indica la distancia (radio) que se encuentran cada uno de los vecinos P al elemento central g_c .

El cálculo de los LBP se puede observar en el ejemplo de la figura 4 [50]. En el ejemplo de la Figura 4 se observa la aplicación de las funciones (2-1) y (2-2) para $P = 8, R = 1$.

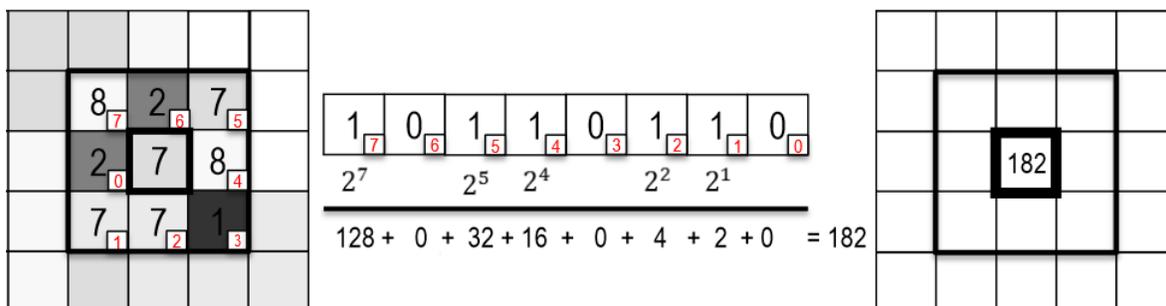


Figura 4. Cálculo de LBP (Fuente: Bikramjot).

Un ejemplo de vecindario para diferentes valores de R y P se puede ver en la Figura 5 [51]. A mayor distancia entre píxeles vecinos disminuye la correlación, es por ello que se usan en la práctica valores de R muy pequeños $R = \{1, 2, 3\}$.

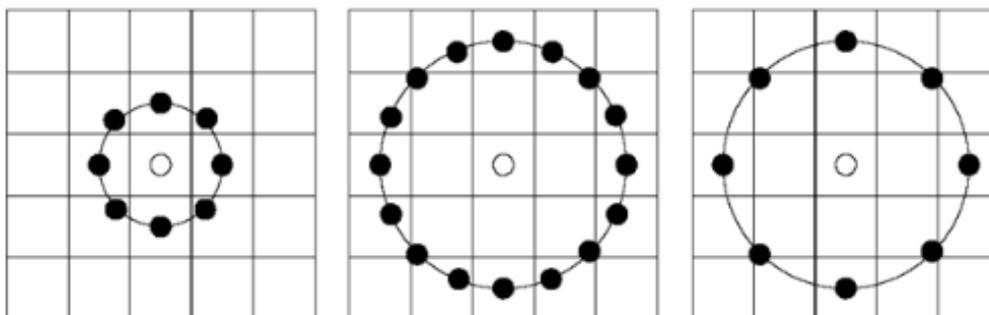


Figura 5. Vecindad de píxeles (Fuente: H.R.E Doost).

La dimensión del vector característica depende del parámetro P. Para $P = 8$ el vector de características extraídas es de 256 elementos.

Cada píxel de la imagen es procesado usando el operador a fin de obtener los patrones locales binario. Las características son obtenidas con este método al calcular un histograma que tiene los valores con la frecuencia de aparición de cada patrón local. Ejemplo de texturas y su

correspondiente histograma se observa en la Figura 6. Cuando las texturas son diferentes el histograma del operador también lo es.

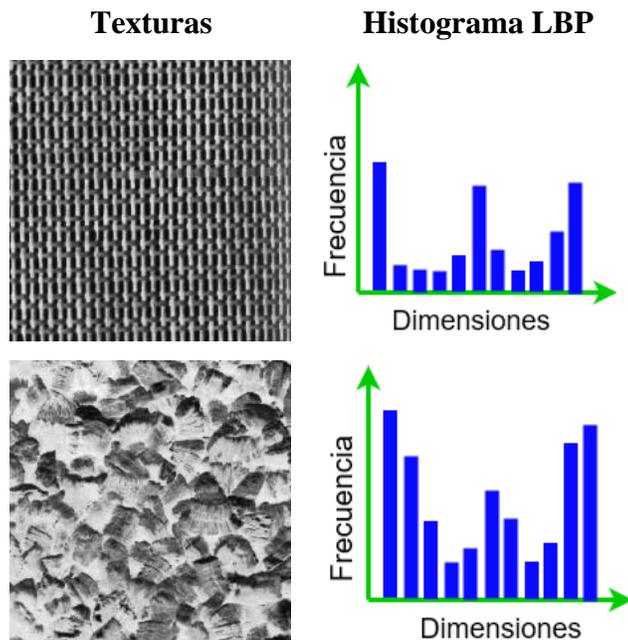


Figura 6. Texturas y su histograma luego del operador LBP.

Otra característica importante de los histogramas de patrones locales binarios es que son invariante a iluminación homogénea ver Figura 7. Esto debido a que sólo tiene en cuenta el signo de las diferencias como se indica en la ecuación (2-2).

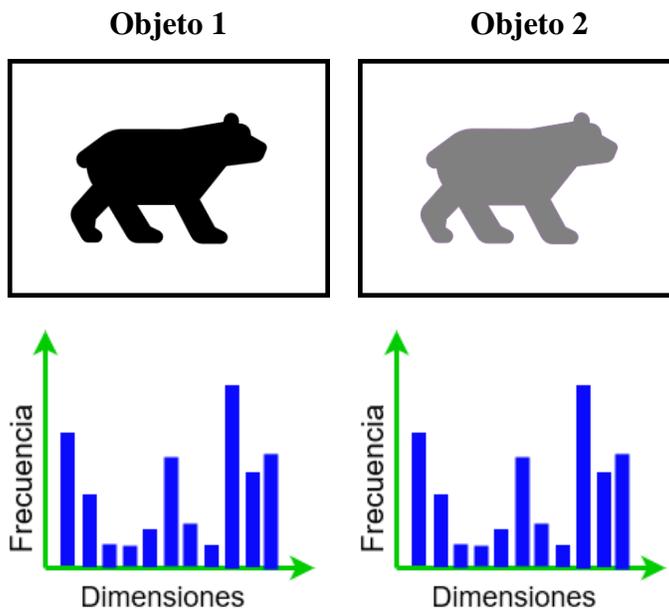


Figura 7. Histograma de objetos con valores iguales.

2.3.2 LBP U2

El método LBP u2 (Patrones Uniformes) [48] pretende reducir el número de patrones en el histograma LBP. Para ello se basa en una medida de uniformidad “u” la cual sólo cuantifica en el histograma de valores LBP donde existen como máximo 2 transiciones de 0 a 1 o de 1 a 0 como se muestra en la Figura 8 [48].

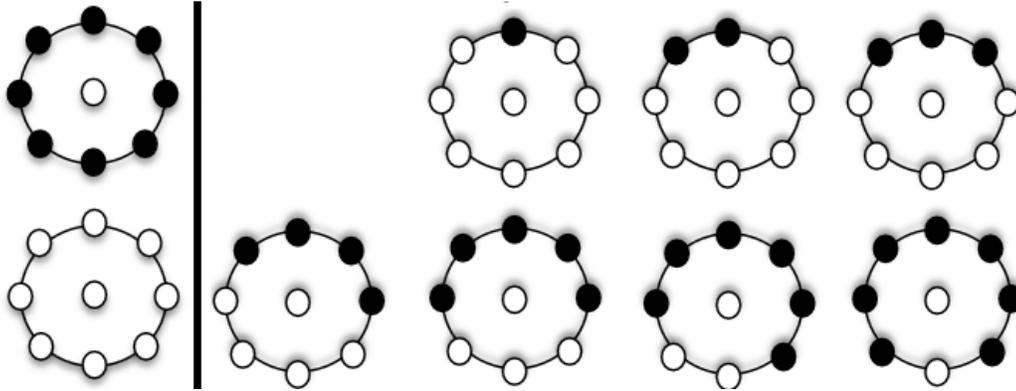


Figura 8. Patrones uniformes. (Fuente: Ojala).

Al resto de los patrones LBP no uniformes se les asigna un patrón individual. Para valor de $P = 8$ entonces el vector característico se reduce de 256 elementos a sólo 58 elementos de los valores uniformes más 1 elemento de los no uniformes para un total de 59.

2.3.3 CLBP

El algoritmo CLBP (*Completed Modeling Local Binary Pattern*) [52] es una mejora al algoritmo LBP [48]. La principal diferencia con respecto al LBP original es que la representación local de un píxel tiene en cuenta las diferencias de signo (2-3), así como la magnitud de las diferencias. Un patrón CLBP se descompone en dos componentes CLBP_Sign para las diferencias de signo y CLBP_Mag para la magnitud de las diferencias. La parte CLBP_Sign de CLBP es equivalente al LBP original [48]. La idea es ilustrada en la Figura 9 [52]. La representación del signo en un histograma es una buena característica de textura y preserva más información de las diferencias locales. Esto explica porque el algoritmo LBP ofrece buenos resultados en representar la textura local, sin embargo, tener en cuenta la magnitud de esas diferencias contribuye y añade más información discriminativa.

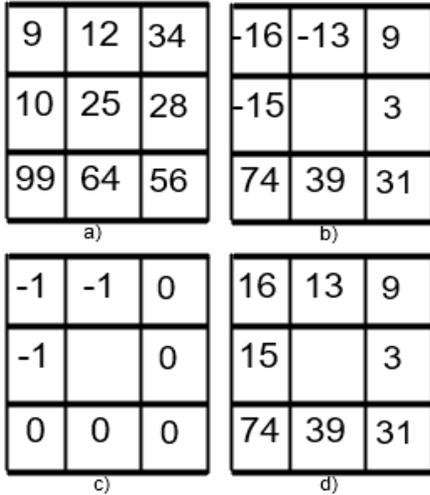


Figura 9. Cálculo de CLBP_Sign y CLBP_Mag (Fuente: D. Zang). (a) Muestra local 3x3, (b) diferencias locales, (c) signo de diferencias, (d) la magnitud.

2.3.4 GLCM

El método de GLCM (Gray Level Co-occurrence Matrix) es una medida para cuantificar la textura en una imagen. Fue primeramente propuesto por Harralick [53] y se considera un método estadístico de análisis de texturas. Las matrices de co-ocurrencia de GLCM indican la frecuencia de aparición de un nivel de intensidad de gris con respecto a otro. Por ejemplo, pueden calcularse las frecuencias de aparición en el nivel horizontal de un valor de intensidad “i” con respecto a un valor de intensidad “j”. Ejemplo del cálculo de la matriz de co-ocurrencia la podemos observar en la Figura 10 [54].

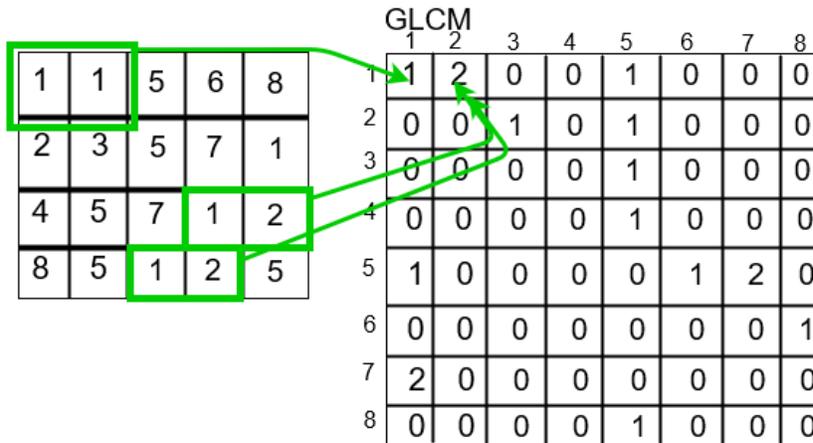


Figura 10. Cálculo de la matriz en dirección horizontal a un píxel de distancia. (Fuente: Mathworks).

Generalmente se utilizan imágenes escaladas y cuantizadas a determinado nivel de intensidad para reducir el tiempo de cálculo y la matriz calculada. Se puede definir además la resolución espacial que no es más que la distancia entre píxeles para calcular la frecuencia de aparición de los valores de intensidad. Una vez calculada la matriz de co-ocurrencia se pueden extraer varias características para representar la textura. Las propiedades de la matriz de co-ocurrencia son los valores que representan las características, los cuales pueden ser obtenidos usando las ecuaciones de la Tabla 1 [55].

Tabla 1. Propiedades de matriz de co-ocurrencia (Fuente: Mathworks).

Contraste	Mide las variaciones locales en niveles de gris de la matriz de co-ocurrencia	$\sum_{i,j} i - j ^2 p(i, j)$	(2-3)
Correlación	Mide la probabilidad de ocurrencia conjunta de un par de píxeles	$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j}$	(2-4)
Energía	Provee la suma de cuadrados de los elementos en GLCM. Se conoce como uniformidad o segundo momento angular	$\sum_{i,j} p(i, j)^2$	(2-5)
Homogeneidad	Mide que tan cercano esta la distribución de los elementos en GLCM a la diagonal GLCM	$\sum_{i,j} \frac{p(i, j)}{1 + i - j }$	(2-6)

2.4 Extracción de regiones

A partir de los años 80 han aparecido las primeras formulaciones de métodos basados en diferenciales para particionar y segmentar imágenes [56], [57]. El *Snakes* [56] es un ejemplo de estos métodos para la segmentación de imágenes utilizando contornos activos. Los modelos de segmentación basados en *Snakes* han sido utilizados para segmentar imágenes médicas [58] [59], seguimiento de vehículos [60], y han sido citados en numerosos artículos que se han publicado [61], [62]. Se han utilizado además para la segmentación de texturas [63], [64], segmentación de objetos por su forma [65] y reconstrucción de objetos 3D [66].

El *Snakes* está basado en la segmentación a partir de detección y agrupación de bordes. Los bordes son una característica de las formas que están presentes en las imágenes y corresponden

a los contornos. Primeramente se analiza la formulación básica de *Snakes* y se describe la formulación del modelo de Bresson [67] para segmentar imágenes utilizando contornos activos aun cuando exista ruido.

2.4.1 Snakes

El método usando *Snakes* se ha utilizado para la segmentación de imágenes. El *Snakes* está basado en una curva deformable que se ajustan a los bordes internos o externos de las imágenes que minimiza una función de energía de la curva cerrada guiada por fuerzas externas [56]. El objetivo del *Snakes* es encontrar una curva cerrada tal que minimice la energía en la detección del contorno que rodea al objeto que se desea segmentar. El *Snakes* puede encontrar bordes no circulares y realiza significativamente la segmentación imágenes [68]. Usar *Snakes* para segmentación usando contornos activos es tener un conjunto ordenado de puntos en una imagen:

$$P = \{p_1, p_2, \dots, p_n\} \quad (2-7)$$

Donde $p_i = (x_i, y_i)$ en la ecuación (2-7) es un punto del contorno. El *Snakes* hace que los puntos definidos se acerquen al borde de un objeto iterativamente a través de minimizar una función de energía. Para cada punto p_i en un vecindario de p_i se calcula la función de energía:

$$E(C) = E_{\text{int}}(C) + E_{\text{ext}}(C) \quad (2-8)$$

Donde E_{int} es la energía interna formada por la configuración de *Snakes*, E_{ext} es la energía externa formada por fuerzas externas afectando el *Snakes* y C es una curva definida por los puntos P . La energía interna E_{int} es dependiente de la forma del contorno y es la suma de la energía de continuidad E_{cont} con la energía de curvatura de contorno E_{curv} . Por otra parte E_{ext} es dependiente de las propiedades de la imagen tales como gradiente. La E_{ext} en términos de gradiente puede representarse como:

$$E_{\text{ext}}(C) = - \int_0^1 |\nabla I(C(s))|^2 ds \quad (2-9)$$

El objetivo es encontrar una curva tal que su energía interna y externa sea mínima para segmentar el objeto. En (2-9) I corresponde a la imagen que se desea segmentar, ∇ es el operador gradiente y $C(s)$ son los valores en la imagen siguiendo un contorno separado en pequeños segmentos de tamaño s como se observa en la Figura 11.

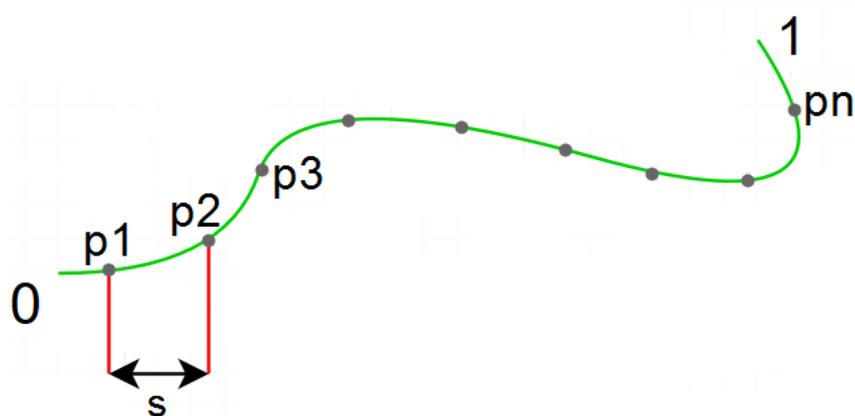


Figura 11. Puntos del Snake.

La expresión anterior (2-9) indica que cuando la suma del gradiente en la curva dentro de la imagen es muy grande entonces la energía externa se hace pequeña por el signo de menos delante de la expresión. Con esto los puntos de *Snakes* se ven atraídos hacia contornos con alto valor de gradiente [56].

La energía en cada punto del contorno puede escribirse como:

$$E_i = \alpha E_{cont,i} + \beta E_{curv,i} + \gamma E_{img,i} \quad (2-10)$$

Donde E_{int} son las restricciones de continuidad y de curvatura:

$$E_{int} = E_{cont} + E_{curv} = \int_0^1 \left\{ \frac{\alpha}{2} |C_s(s)|^2 + \frac{\beta}{2} |C_{ss}(s)|^2 \right\} ds \quad (2-11)$$

C_s y C_{ss} denotan la primera y segunda derivada de la curva con respecto a s . Los términos de regularización de la curva incluyen α , β y γ , en (2-10) son los pesos para cada tipo de energía. Si α es muy grande el punto estará más espaciado. Si β aumenta el ángulo entre el borde del snake se hace más pronunciado. Por último el parámetro γ es el responsable de hacer el punto del snake más sensible a la energía de la imagen en vez de la continuidad o la curvatura. Se busca entonces una curva C tal que su energía sea mínima. La energía que se desea minimizar presenta la siguiente función de costo:

$$E_{snake}(v) = \operatorname{argmin}_C \left\{ \int_0^1 \left\{ \frac{\alpha}{2} |C_s(s)|^2 + \frac{\beta}{2} |C_{ss}(s)|^2 \right\} ds - \gamma \int_0^1 |\nabla I(C(s))|^2 ds \right\} \quad (2-12)$$

Para resolver el problema de minimización se planteó una solución utilizando el método de gradiente descendente [56]. También existen otras soluciones utilizando programación dinámica

[69], algoritmos voraces [70] entre otros. La solución del *Snakes* es una función que minimiza la ecuación (2-12) y la solución cumple las ecuaciones de Euler-Lagrange, pero no de manera inversa.

Debido a los términos de regularización del Snakes (2-11) no es posible tener varias curvas por lo que no se puede detectar simultáneamente varios objetos, aunque la curva inicial los rodee a todos. *Snakes* sólo tiene en cuenta una curva para segmentar y no permite obtener objetos con hoyos interiores. También se dificulta segmentar los objetos en imágenes con ruido debido a la utilización del gradiente como funcional de energía de la imagen. Otro inconveniente es que necesita inicialización cerca del objeto a segmentar y adecuar los parámetros para la segmentación. Tampoco tiene en cuenta información de la textura de la imagen para la segmentación.

2.4.2 Modelos geométricos de contornos activos

Los modelos geodésicos/geométricos (GAC) de contornos activos [71]–[73] están basados en curvas de flujos geométricos [74], [75]. En este modelo la curva se deforma permitiendo cambios automáticos de la topología para la detección simultánea de contornos. Tienen la característica de que son independientes de la parametrización del contorno debido a que no utilizan restricciones de continuidad o curvatura como el caso de la energía interna del snake (2-11).

El método de Bresson [67] por otra parte combina un método de reducción de ruido en conjunto con los contornos activos geométricos. El método de reducción de ruido ROF [76] busca eliminar el ruido en las imágenes manteniendo información de bordes y textura. La unificación del método de reducción de ruido en conjunto con el método de contornos activos geométricos provee una solución de mínimo global sujeto a restricciones de intensidad homogéneas [67]. La función de costo a minimizar en este modelo es:

$$\min_{u,v} \left\{ E(u, v, \lambda, \theta) = \int_{\Omega} g(x) |\nabla u| dx + \frac{1}{2\theta} \int_{\Omega} (u + v - f)^2 dx + \lambda \int_{\Omega} |v| dx \right\} \quad (2-13)$$

$$g(|\nabla I_0|) = \frac{1}{1 + \beta |\nabla I_0|^2} \quad (2-14)$$

La función $g(x)$ [67] es un indicador de bordes que desaparece en los límites del objeto, I_0 es la imagen original, u representa la información geométrica de las partes de cada forma y v representa información de la textura [67]. La solución del modelo a minimizar se obtiene por un método numérico iterativos [67]. Ejemplo de aplicación del algoritmo lo podemos observar en la Figura 12.

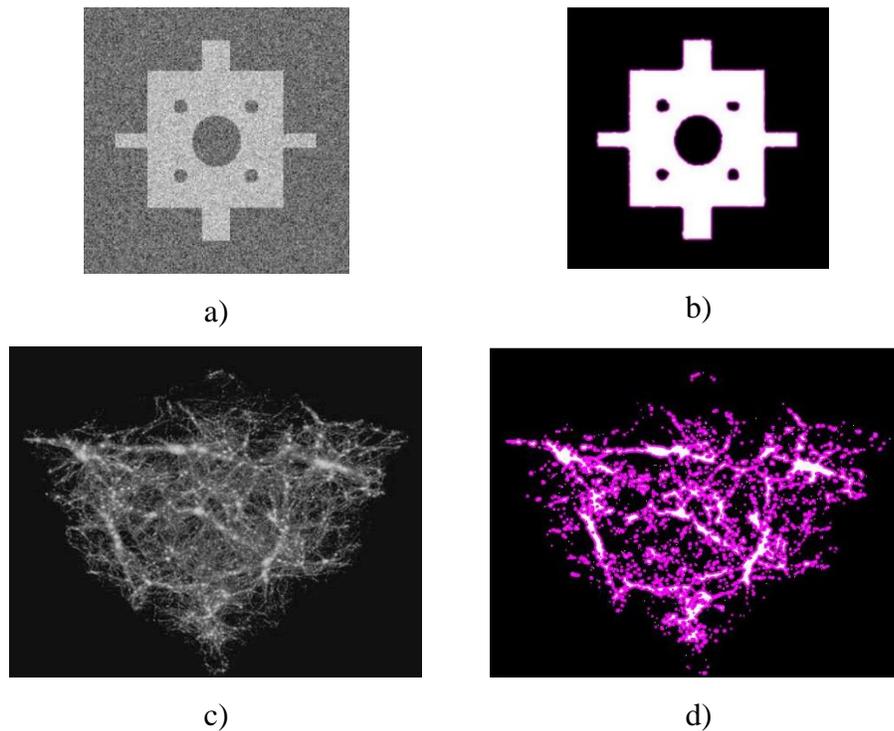


Figura 12. Segmentación ROF+CA. a) Imagen ruidosa con contornos interiores, b) segmentación de la imagen ruidosa con los contornos interiores (Fuente: Bresson). c) objeto irregular, d) segmentación del objeto irregular.

Como se observa en la Figura 12 [67] las formas geométricas pueden detectarse aunque exista ruido en las imágenes de varios objetos y con presencia de hoyos. Se tiene en cuenta información de la textura para la separación entre regiones geométricas lo que mejora la segmentación. El modelo de Bresson por tanto mejora el desempeño del modelo Snake y es eficiente aun cuando el contraste entre el objeto significativo y el fondo es bajo [67].

2.4.3 Propiedades de las regiones

El proceso de obtener formas geométricas a partir de segmentación en las imágenes ofrece como resultado varias formas geométricas, cada una con diferentes propiedades que se necesita sean descritas con motivos de comparación. Si se localiza cada forma segmentada y se etiqueta con el propósito de describir las propiedades de la forma, se necesita cuantificar sus medidas. Los descriptores de forma se pueden obtener a través de medir los píxeles que componen la región de la forma, píxeles del contorno de la forma, vértices, esquinas o puntos característicos del esqueleto de la forma. Podemos diferenciar entre dos clases de descriptores de región de las formas, los geométricos y los topológicos. Los descriptores geométricos permiten describir propiedades geométricas de la forma, como su área y su perímetro. Por otra parte, los descriptores topológicos permiten describir propiedades que tienen que ver con la estructura de la forma, el número de hoyos y el número de Euler son ejemplos de estos descriptores topológicos. A continuación, se describen dichos descriptores de forma.

Entre los descriptores topológicos se encuentra el número de Euler que ha sido utilizada en varias aplicaciones de visión por computadora [77], [78]. Esta característica relaciona el número de componentes del objeto NC y el número de hoyos NH de la siguiente manera:

$$E = NC - NH \quad (2-15)$$

Existen varios métodos que proponen calcular el número de Euler de los objetos. Algunos de estos algoritmos están basados en obtener los vértices, caras cuadradas y bordes de un grafo cuadrado de una imagen. También es posible calcular el número de Euler determinando la matriz de adyacencia de los píxeles y de sus vecinos con una conectividad a ocho (ver Figura 13).

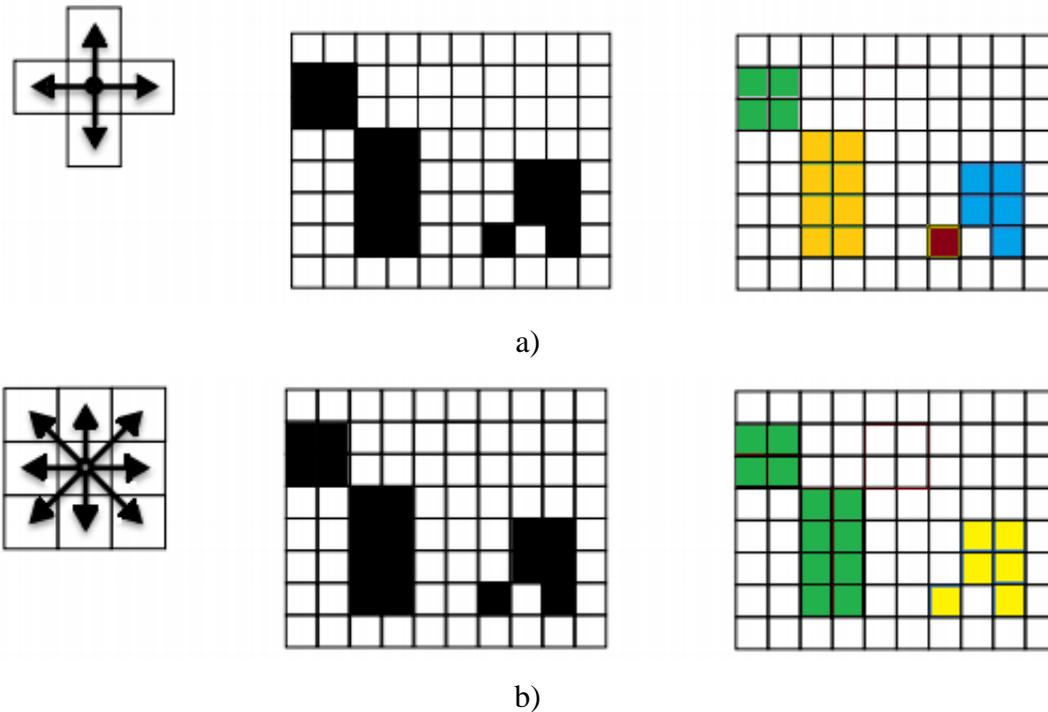


Figura 13. Conectividad de píxeles a) cuatro conectividad, b) ocho conectividad.

Calcular el número de Euler a partir de la matriz de adyacencia cuando la imagen presenta objetos muy grandes puede ser ineficiente debido a que ocurre desbordamiento de pila por las llamadas recursivas en la función de recorrido. Otros algoritmos se basan en determinar el número de Euler a partir del esqueleto de un objeto sabiendo que este preserva los hoyos.

Los descriptores geométricos por otra parte, son el área de un objeto y el perímetro. Estos nos dan una medida de su tamaño y puede ser estimado contando la cantidad de píxeles que forma el objeto. El perímetro de un objeto puede estimarse contando el número de píxeles que forman el contorno del objeto. Un píxel es de contorno si tiene como vecino al menos un píxel de fondo. El perímetro es diferente dependiendo de la conectividad de los píxeles que se tenga en cuenta. Otro de los descriptores geométricos que puede determinarse es el factor de compacidad FC o de irregularidad. Este puede describirse como el perímetro al cuadrado del objeto dividido 4π veces su área:

$$FC = \frac{P^2}{4\pi * A} \tag{2-16}$$

El factor de compacidad normalizado $[0...1]$ mide que tan cerca se encuentra la forma de un objeto a la de un círculo, siendo 1 para objetos circulares y 0 para objetos irregulares. Esto nos da una medida para saber cuan redondeado es el objeto.

2.5 Desempeño de extracción de características de textura

Para evaluar los descriptores de textura se analizaron varios métodos de extracción de características que representan la información de la textura. Existen variados métodos que permiten representar en forma numérica la información de la textura (cf Secciones 2.3). Se desea conocer cuál de los métodos analizados puede ser el más discriminativo y posteriormente utilizarlo en representar la textura de un iris. Se realizaron experimentos que miden el desempeño de los métodos analizados utilizando bases de datos de textura que más se asemejan a la textura de un iris. Se realizó una búsqueda exhaustiva variando todos los parámetros de cada método en cada base de datos y aplicando un algoritmo de clasificación. Una vez realizada la clasificación podemos medir el desempeño de cada uno de los métodos y de esta manera se obtienen los métodos que mejor extraen las características.

2.5.1 Métodos evaluados

Se seleccionaron los métodos de las secciones 2.3 así como también otras variaciones basados en LBP como son SLBP [79] , LPQ [80] para evaluar el desempeño con las bases de datos que se describen más adelante en la sección 2.5.2. En cada uno de los métodos analizados anteriormente fue comparado su desempeño.

La implementación del algoritmo LBP está disponible y es de libre uso en el Departamento de Ciencias de la Computación e Ingenierías de la Universidad de OULU³.

Se buscó en cada método el valor de los parámetros que discriminara mejor entre texturas en la base de datos. La Tabla 2 muestra el espacio de búsqueda de la variación de los parámetros que dependen del método que se está evaluando.

³ <http://www.cse.oulu.fi/CMV/Downloads/LBPmatlab>

Tabla 2. Parámetros de métodos y espacio de búsqueda.

Parámetro	Intervalo	Método aplicado
P número de muestras	$P \in \{2,3,4,\dots,20\}$	LBP,CLBP
R distancia de las muestras al píxel central	$R \in \{1,2,3,\dots,20\}$	LBP,CLBP
Shift Limits	$l \in \{1,2,3,\dots,20\}$	SLBP
Quantización	$q \in \{3,4,5,\dots,20\}$	GLCM
Distancia	$d \in \{1,2,3,\dots,20\}$	GLCM

2.5.1 Metodología de evaluación

Se utilizaron los métodos (cf. Sección 2.3) para clasificar bases de datos de texturas con el algoritmo de clasificación 1-NN y de esta forma evaluar la precisión [81]. El método 1-NN utiliza la distancia euclidiana para medir la similitud de las características. Cada método es evaluado (cf. Sección 2.3) verificando la precisión utilizando validación cruzada en la clasificación. La validación cruzada ayuda a un mejor aprovechamiento de las imágenes de entrenamiento y prueba de las bases de datos de texturas de las evaluaciones. Con la validación cruzada es garantizado la independencia de las particiones de los datos en el entrenamiento y prueba es garantizada. Tiene la desventaja que es un proceso lento pero es muy preciso en la evaluación de resultados [82]. La validación consiste en dividir el conjunto de muestras en subconjuntos n . Se le asigna a cada muestra un valor n aleatoriamente. Si se seleccionan $n = 10$ esto crea un subconjunto disjunto de 10 grupos con aproximadamente igual número de muestras en cada subconjunto. En la primera iteración de validación cruzada $n = 1$, se entrena el clasificador con los $n = \{2, 3 \dots, 10\}$ restantes subconjuntos y el grupo $n = 1$ se utiliza como prueba. En la segunda iteración para $n = 2$ se entrena el clasificador con los $n = \{1, 3, 4 \dots, 10\}$ restantes subconjuntos y el subconjunto de prueba que se utiliza es $n = 2$. Esto significa que cada muestra de cada clase puede ser utilizada como prueba al menos una vez. El desempeño de los 10 resultados de los grupos es combinado en una sola estimación.

Los experimentos se realizaron introduciendo filtro gaussiano con el objetivo de simular imágenes capturadas fuera de foco por una cámara. Se utilizó un kernel de tamaño 11 x 11 a partir de discretizar la ecuación de la gaussiana en dos dimensiones (2-4). Se varió el parámetro

de desviación de la gaussiana en los experimentos. Los valores escogidos para la desviación fueron de sigma (σ) = {0.5, 1, 1.5, 2, 2.5, 4, 6} en la ecuación (2-4).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (2-4)$$

2.5.2 Bases de datos de textura

Las bases de datos seleccionadas para evaluar los algoritmos de extracción de características de textura fueron seleccionadas de forma que se asemejaran a la textura de un iris. Se seleccionaron para los experimentos las bases de datos de mármoles Marmi [79] y Broadtz [83]. Ejemplo de las texturas presentes en la base de datos lo podemos ver en las Figura 14 [83] y Figura 15 [79].

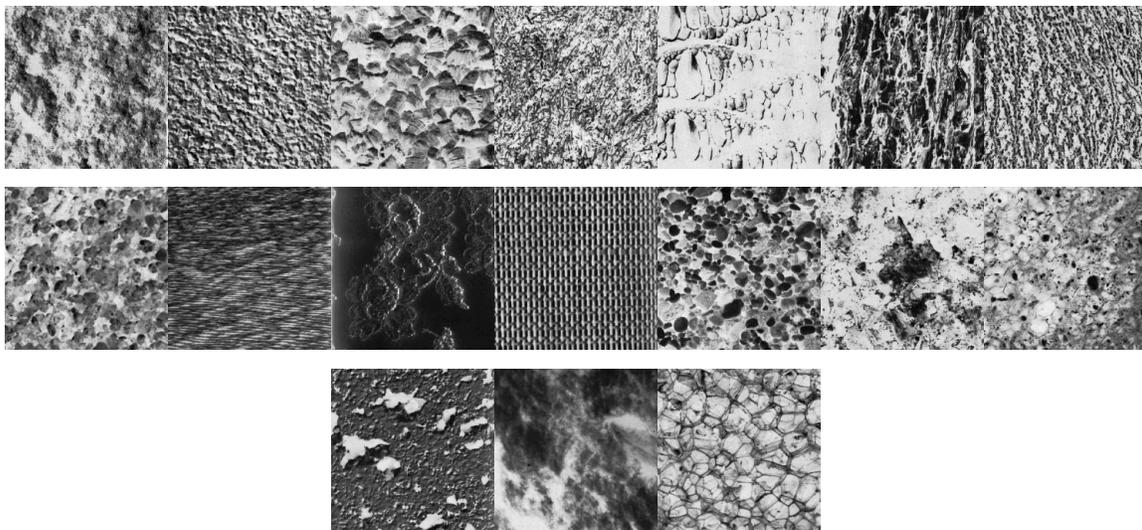


Figura 14. Base de datos Broadtz (Fuente: Phil Broadtz).

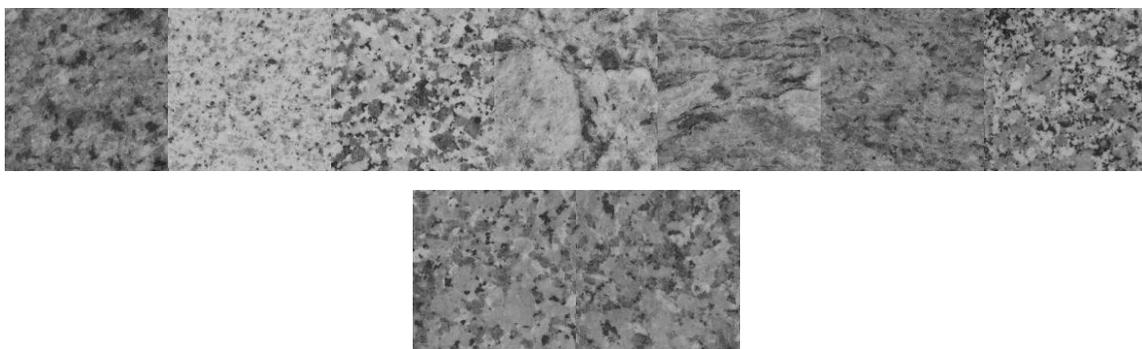


Figura 15. Base de datos Marmi (Fuente: A. Fernández).

La cantidad de muestras por cada clase de textura así como propiedades de formato y tamaño de las bases de datos utilizadas para evaluar la podemos observar en la Tabla 3.

Tabla 3. Propiedades de las bases de datos.

Bases	Clases	Muestras	Total	Tamaño	Formato	Referencia	Web
Brodatz	111	9	999	213 px	GIF	[83]	[84]
Marmi	12	16	192	272 px	JPEG	[79]	[85]

2.5.3 Resultados

Los resultados de la clasificación usando la metodología propuesta en 2.5.1 se puede observar en las Tabla 4 y Tabla 5. El valor de desempeño máximo se encuentra luego de clasificar con cada método y cada base de datos variando los valores de los parámetros en el espacio de parámetros de cada método (ver Tabla 2). Los valores de mejor desempeño en la clasificación de texturas se marcan en color negro, un valor sombreado indica el peor desempeño del algoritmo.

Tabla 4. Base de datos Mondial Marmi.

Nivel de desenfoco	-	0.5	1	1.5	2	2.5	4	6
LBP	85.41	83.87	80.16	73.96	72.36	70.23	63.52	49.48
CLBP	98.96	96.88	93.23	89.58	87.5	86.98	82.81	77.60
LPQ	93.23	97.92	96.88	94.79	95.31	89.06	86.98	81.77
SLBP	91.15	90.10	82.29	75.00	71.86	73.44	66.68	73.44
GLCM	88.02	86.46	83.33	82.81	75	73.96	66.67	59.36

Tabla 5. Base de datos Brodatz.

Nivel de desenfoque	-	0.5	1	1.5	2	2.5	4	6
LBP	95.30	94.30	94.25	91.14	85.48	84.69	74.62	70.21
CLBP	96.50	95.80	95.10	92.69	89.89	86.79	78.98	68.47
LPQ	95.30	95.70	97.10	95	93.59	92.29	86.49	79.08
SLBP	94.39	94.69	94.59	93.29	91.59	89.79	82.18	71.67
GLCM	76.57	75.98	75.26	76.01	71.87	64.16	50.05	34.33

Para valores con poco desenfoque (0.5), algunos de los descriptores muestran un ligero incremento en la clasificación. Esto ocurre pues filtrar con una función gaussiana para agregar desenfoque causa el efecto de eliminar el ruido si utilizamos valores pequeños de sigma (2-4). Cuando la sigma del filtro gaussiano (2-4) es grande reduce el ruido, pero destruye los bordes donde existen cambios en la intensidad de los píxeles, por consiguiente, se pierde información de textura y la imagen aparece más degradada.

Todos los descriptores se ven afectados por el desenfoque en las imágenes. Como la intensidad de los píxeles y las formas en las estructuras cambian de manera impredecible con esta deformación la mayoría de los descriptores no son robustos a niveles altos de desenfoque. El descriptor LPQ es más robusto a desenfoque comparado con otros descriptores de textura. En bases de datos con texturas con muchas esquinas el LPQ ofrece los mejores resultados. El descriptor CLBP supera al LBP en la clasificación de todas las bases de datos para valores con poco desenfoque.

2.6 Conclusiones

Es deseable que los descriptores de las características de textura sean representados de forma compacta, tengan un alto grado de discriminación y permitan establecer relaciones de semejanza o diferencias en las imágenes. Otro punto importante a partir de la revisión de métodos descriptores de características de textura es que al aplicar los algoritmos se desea que los descriptores resulten muy similares para las mismas texturas. Dado dos imágenes de una misma textura por ejemplo tomada bajo diferente perspectiva, es deseable que se detecten la mayor cantidad de características similares en ambas imágenes utilizando los métodos.

Usar descriptores para las texturas que no analizan todos los píxeles de la imagen discrimina muchas características en el iris debido a que sólo se obtienen los valores distintivos en determinadas zonas de la imagen. En el caso del descriptor SIFT sólo obtiene puntos con fuerte respuesta en el espacio de escala, se descartan zonas que también poseen información discriminante en la textura del iris. Por otra parte, los descriptores de textura que analizan cada píxel en la imagen para la descripción del contenido de textura han tenido un buen desempeño. El proceso de analizar cada píxel de la imagen es útil debido a que permite extraer bien las características en toda la textura. Finalmente, las evaluaciones de los descriptores de características de texturas fueron evaluados en bases de datos de textura bajo diferentes niveles de desenfoque y como resultado se obtuvieron los métodos más discriminativos CLBP y LPQ. Para describir la textura de un iris extrayendo las estructuras geométricas, no es conveniente utilizar el *Snakes* en imágenes con ruido, esto debido a que la energía externa se puede hacer mínimo (máximo gradiente) en cualquier posición de la imagen que rodee la forma geométrica. El *Snakes* tampoco permite detección simultánea de contornos y necesita que sea inicializado en alguna región de la imagen que rodee el objeto a segmentar. El *Snakes* por sus limitantes no representa una opción viable para extraer las formas geométricas. Debido a que en las imágenes de textura de iris pueden existir múltiples criptas o surcos no es factible utilizarlo en imágenes donde se deseen detectar varias estructuras. Por otra parte, el modelo de contornos activos geométricos permite detectar simultáneamente varias regiones geométricas como resultado de la segmentación. Si se conoce que la textura del iris presenta ruido, el algoritmo más adecuado es el de Bresson. Para poder utilizar descriptores geométricos y topológicos es necesario localizar las estructuras geométricas segmentadas y aislarla con el fin de cuantificar sus medidas.

3 Modelo propuesto de representación de la textura del iris

El modelo propuesto define una función E para representar las características distintivas. Para cada muestra biométrica de la textura del iris p en un universo de muestras P , la función $E : P \rightarrow F$ mapea cada muestra $p \in P$ con su correspondiente representación en forma de vector $f \in F$ en el espacio de características. Las características distintivas extraídas se almacenan para su posterior comparación en una base de datos. Si se denota la base de datos como $B := \{m_1, m_2, \dots, m_n\}$, entonces cada persona $m_i \in B$ se caracteriza por un par de datos $m_i := (i, f_i)$ para $i = 1, \dots, n$ donde i es la etiqueta de la persona (ID) y f_i es el correspondiente vector de características.

Los vectores de características son luego comparados usando una función $C : (F, F) \rightarrow \mathbb{R}$ devolviendo un valor de similitud o disimilitud que indica el grado de parecido entre dos vectores de características (f_1, f_2) .

El modelo propuesto tiene en cuenta la permanencia de las regiones segmentadas en la textura del iris, así como las características de contraste en las texturas locales en la comparación de dos texturas de iris.

Las características de contraste en la textura del iris son extraídas con el algoritmo LBP (cf Sección 2.3.2) para obtener la primera función E_1 . Para comparar las características de texturas extraídas se define una primera función de comparación C_1 que conforma el primer criterio de reconocimiento (*score1*).

Las regiones segmentadas fueron obtenidas con el método de contornos activos geométricos propuesto por Bresson [67] (cf Sección 0) lo cual permite obtener las formas geométricas de la textura del iris aunque exista ruido. Con la segmentación de las regiones se obtiene la función E_2 para representar las características de formas geométricas de la textura del iris. Posteriormente se define una función de comparación C_2 para comparar las regiones geométricas segmentadas que conforma el segundo criterio de reconocimiento del modelo propuesto (*score2*).

Teniendo las funciones E_1, C_1, E_2, C_2 se obtiene un modelo que permite combinar ambos criterios de comparación C_1, C_2 de diferentes características extraídas E_1, E_2 en un sólo modelo de reconocimiento final (*score*).

3.1 Criterio parte 1. Comparación de características de textura

Para obtener el primer criterio de comparación se propone utilizar los algoritmos de extracción de características de contraste (cf. Sección 2.3). El algoritmo seleccionado fue primeramente evaluado su desempeño en bases de datos de texturas que se asemejan a la textura de un iris como se muestra en la sección 2.5.

El esquema que representa el primer criterio de comparación lo podemos observar en el esquema de la Figura 16.

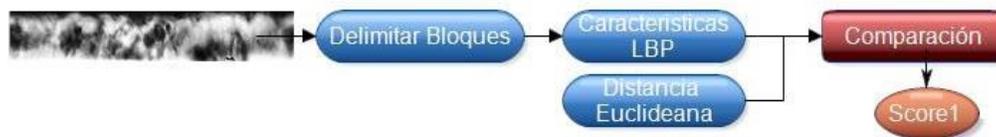


Figura 16. Primer criterio de reconocimiento.

Dada una representación en forma rectangular la textura del iris se extraen las características de contraste en diferentes regiones de la imagen a partir de delimitar por bloques la textura y luego se utiliza una función de comparación.

3.1.1 Delimitar bloques

En los enfoques analizados en la sección 2.2 se extraen las características en diferentes zonas de la textura del iris. En algunos de los trabajos analizados en la sección 2.2 utilizan parches, delimitaciones por regiones que le llaman celdas o procesamiento por bloques en la textura del iris. Para extraer las características de contraste se optó por dividir en bloques de igual tamaño (ver Figura 17) la textura del iris. Las comparaciones por bloques tienen la ventaja de que no se necesita que toda la textura del iris esté presente entre ambas imágenes [30].

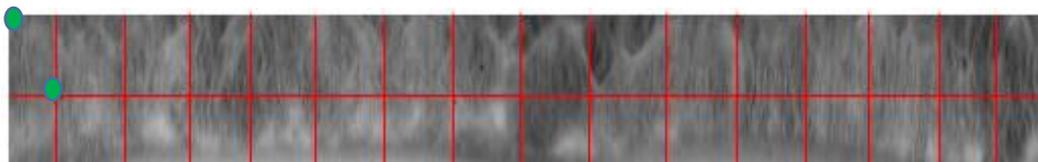


Figura 17. División de la textura del iris.

Extraer las características en cada bloque permite representar mejor de forma local y global debido a que se tiene en cuenta la localización espacial de los bloques que tienen las características de toda la textura del iris. La división por bloques permite además que las

características extraídas se obtengan en toda la textura del iris delimitando los vectores de características en cada localización.

3.1.2 Características LBP

Primeramente se realiza el cálculo de las características basados en el algoritmo LBP a la textura del iris (ver Figura 18).

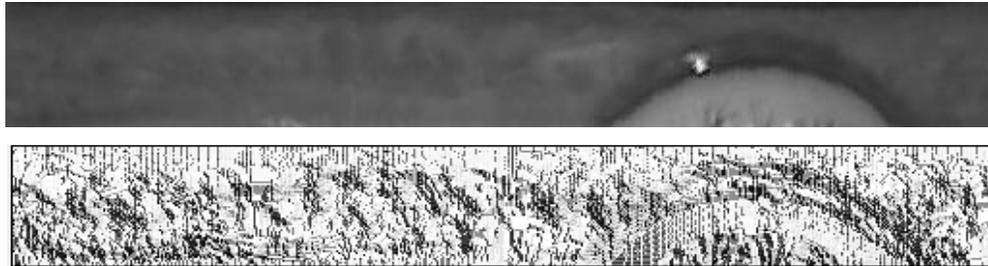


Figura 18. Procesamiento LBP.

El vector de características de una textura de iris es obtenido al dividir en bloque y concatenar los histogramas de LBP en cada división (cf Sección 3.1.1) luego de procesar con el algoritmo LBP toda la textura.

$$E_1(p) = \cup LBP(b) / \forall b \in p \quad (3-1)$$

La ecuación E_1 representa la función para extraer las características en la textura p y b representa un bloque en el que fue dividido la textura. En (3-1) se representa el vector de características como la unión de los histogramas de los patrones locales binarios con las características de cada bloque para todos los bloques en que fue dividida la textura del iris.

3.1.3 Distancia Euclidiana

Para la comparación de los histogramas LBP se utiliza algún método que permita obtener la distancia entre vectores de características. La distancia euclidiana se adapta a la función de comparación de vectores debido a que se suman las diferencias de errores en cada posición del histograma.

$$d(f_1, f_2) = \sqrt{\sum_{i=1}^N (a_{1i} - b_{2i})^2} = \sqrt{(b_1 - a_1)^2 + (b_2 - a_2)^2 + (b_N - a_N)^2} \quad (3-2)$$

Se tiene en (3-2) dos vectores de características $f_1 = \{a_1, a_2, \dots, a_N\}$ y $f_2 = \{b_1, b_2, \dots, b_N\}$ de tamaño N, donde $\{a_1, a_2, \dots, a_N\}$ y $\{b_1, b_2, \dots, b_N\}$ representan los valores del histograma de los patrones LBP con las características de f_1 y f_2 respectivamente. A mayor distancia $d(f_1, f_2)$ entre los vectores f_1, f_2 en la formula (3-2) indica que son más diferentes las texturas. Por el contrario, si las distancias de los vectores con los histogramas LBP son cercanas a cero entonces las texturas son muy similares.

3.1.4 Comparación por bloques

Para la comparación se utilizó la distancia euclidiana como función de comparación de características en cada bloque. Esto es:

$$C_1(p_1, p_2) = \text{CB}[d((E_1(p_1), E_1(p_2)))]$$

donde $d(E_1(p_1), E_1(p_2))$ (3-2) es la distancia euclidiana entre vectores de características (3-2) y $f_1 = E_1(p_1), f_2 = E_1(p_2)$ es la concatenación de los histogramas de cada uno de los bloques usando el algoritmo LBP para las texturas de iris ver 3.1.1. En CB se refiere a la cantidad de bloques que cumplen con los siguientes criterios:

1. El valor de la distancia $d(f_1, f_2)$ debe de ser menor que un umbral obtenido de comparaciones entre bloques de texturas iguales en la misma localización.
2. La distancia del bloque $d(f_1, f_2)$ de un bloque en la textura de una posición con respecto al bloque de igual posición en la otra textura debe de ser menor a cualquier comparación con un bloque comparado en diferente posición.

El primer criterio de comparación C_1 obtiene la cantidad de bloques coincidentes entre dos texturas. A mayores bloques coincidentes indica que la representación espacial de las texturas de iris es más cercana y por lo tanto son más similares.

3.2 Criterio parte 2. Comparación de formas geométricas

Para una mejor representación de las formas geométricas que están presentes en las criptas y surcos (cf. Sección 2.1) en la textura de un iris, se utilizó el modelo de Bresson (cf. Sección 2.4.2) para la segmentación dentro de las imágenes de textura de iris. La segmentación ofrece varias formas geométricas y se necesita verificar que permanezcan entre los iris de las personas. A mayor cantidad de formas geométricas similares entre dos texturas de iris segmentadas indica

que son más parecidas y es más probable que pertenezcan a la misma persona. La evaluación de la permanencia de las formas geométricas segmentadas es el segundo criterio de comparación utilizado como se observa en el esquema de la Figura 19. La permanencia de la segmentación fue obtenida al calcular la correspondencia entre dos segmentaciones utilizando el índice J.

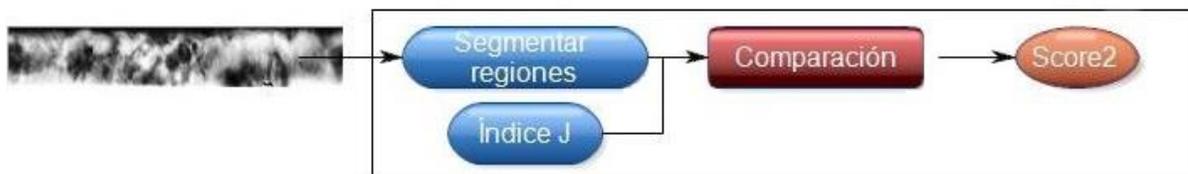


Figura 19. Segundo criterio de reconocimiento.

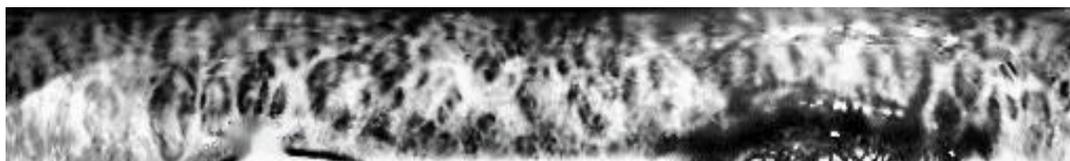
3.2.1 Obtención de regiones

El bloque “segmentar regiones” en la Figura 19 se realiza a la textura de iris para extraer las características de las formas geométricas.

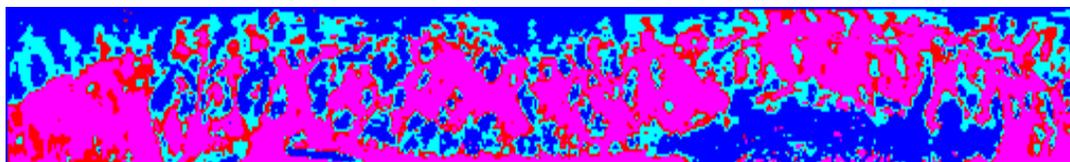
De esta manera el segundo método para extraer características de forma se obtiene de:

$$E_2(p) = Segm(p)$$

De este modo las características que representan las formas geométricas dentro de la textura del iris conforma la segunda función E_2 . Ejemplo de aplicación del método de segmentación de las regiones geométricas lo podemos observar en la Figura 20.



a) Textura del iris.



b) Regiones geométricas segmentadas.

Figura 20. Resultado de la segmentación de las regiones.

3.2.2 Índice J

Su utilizó el índice de Jaccard para calcular la correspondencia entre la segmentación de texturas de iris. El índice de Jaccard (Jacc) cuantifica el grado de similitud entre dos conjuntos. Se ha sido utilizado como métrica para evaluar segmentación de objetos en imágenes [86], [87]. La fórmula para calcular el índice se observa en la ecuación:

$$J(A,B) = \frac{|A \cap B|}{|A \cup B|} \quad (3-3)$$

Este puede ser calculado a partir de la relación entre la intersección y la unión de dos conjuntos como se observa en la ecuación (3-3). Un ejemplo de intersección y unión de conjuntos lo podemos observar en la Figura 21. Los conjuntos A y B en la Figura 21 se intersectan en $A \cap B$ delimitado en la región color rojo. La unión ($A \cup B$) de los conjuntos A y B se representa en la Figura 21 dentro de la región delimitada de color azul.

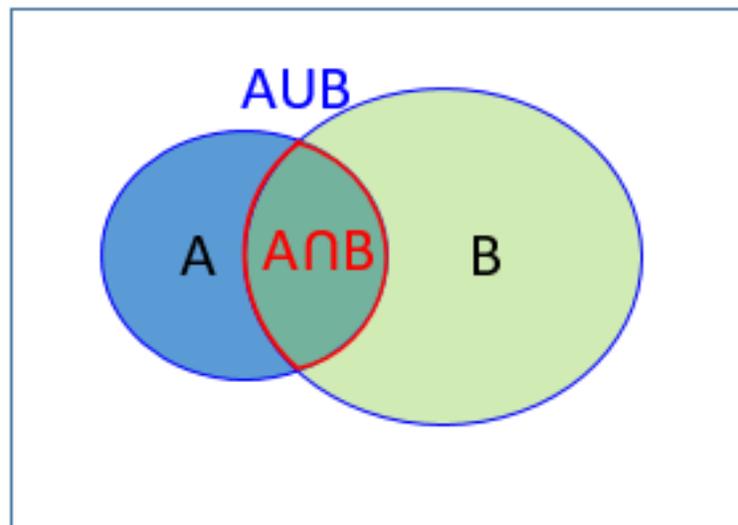


Figura 21. Ejemplo de intersección y unión de conjuntos.

El resultado de calcular el índice es un valor real entre cero y uno [0 1]. Un valor cero o cercano a cero indica que los conjuntos no coinciden. Un valor cercano a 1 indica que existe alta correspondencia o solapamiento entre los conjuntos. Otra medida análoga es la distancia de Jaccard que no es más que $1 - \text{índice Jacc}$. Al realizar la resta la interpretación es totalmente contraria al índice, un valor 0 indica conjuntos muy similares y un valor cercano a 1 indica conjuntos diferentes.

Si se toma la consideración de que los conjuntos A y B es el resultado de algún método de segmentación, entonces el índice Jacc permite comparar las similitudes o diferencias de ambas segmentaciones. Dada dos imágenes f1 y f2 con el resultado de las segmentaciones:

$$f1(x,y) = \begin{cases} 1 & \text{si } (x,y) \in A \\ 0 & \text{en otro caso} \end{cases} \quad (3-4)$$

$$f2(x,y) = \begin{cases} 1 & \text{si } (x,y) \in B \\ 0 & \text{en otro caso} \end{cases} \quad (3-5)$$

donde A, B en (3-4), (3-5) es el dominio en binario de la forma, el índice cuantifica que tan parecidas son las segmentaciones f1 y f2. Ejemplo de dos segmentaciones (rojo y azul) con diferente posición espacial, permanencia y formas geométricas se muestran en la Figura 22.

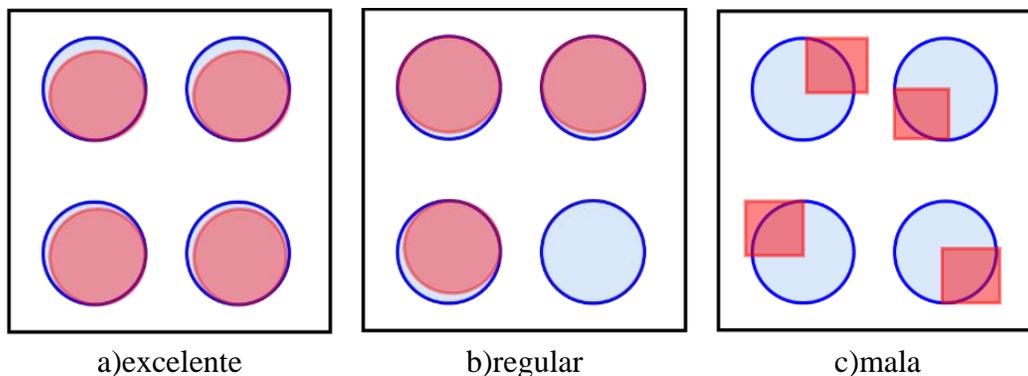


Figura 22. Diferentes valores de Jacc para diferentes ejemplos de las formas:

a) J = 0.92, b) J = 0.72, c) J = 0.25.

En la Figura 22c se observa que las segmentaciones rojo y azul son totalmente diferentes. Las diferencias de la Figura 22c radican en tamaño del objeto y forma geométrica, es por eso que el valor de índice es muy bajo (0.25). En la Figura 22b la forma de las segmentaciones de las regiones geométricas es muy parecida y se encuentran en la misma localización espacial. Lo anterior favorece el índice Jacc = 0.72 debido a que tres de los cuatro objetos tienen la misma forma y localización aunque no está la presencia del cuarto objeto (ver Figura 22c) inferior derecha. Por ultimo en la Figura 22a se puede observar la coincidencia espacial de los objetos y la permanencia de las regiones geométricas de ambas segmentaciones lo que resulta en un índice Jacc de 0.92. Lo anterior indica que cuando las regiones geométricas se asemejan en la segmentación, están en la misma localización espacial y permanecen entonces el cálculo del índice Jacc es alto.

Se utilizó el índice Jacc no para evaluar el resultado de la segmentación con respecto a segmentaciones manuales, sino con el objetivo de medir la correspondencia de las

segmentaciones entre una misma persona y personas diferentes. Esto fue posible debido a que al calcularlo tiene en cuenta la permanencia de las regiones geométricas, así como la estructura topológica de las formas geométricas y la localización espacial de las formas.

3.2.3 Comparación

Para la comparación entre dos texturas segmentadas (cf Sección 3.2.1) se utilizó la medida Jaccard (cf. Sección 3.2.2) para conformar el segundo criterio de comparación:

$$C_2(p_1, p_2) = J [E_2(p_1), E_2(p_2)]$$

Con esto obtenemos el *score2* para reconocer iris a partir de las regiones geométricas segmentadas.

3.3 Modelo propuesto

El modelo propuesto en este trabajo se basa en unificar dos criterios de comparación en un único valor(*score*) resultado. El primer criterio de comparación es extrae las características de textura basados en LBP a cada bloque de una textura de iris y comparando con la distancia euclidiana entre bloques (cf. Sección 3.1). Las características extraídas con el primer criterio son invariantes al contraste de la iluminación homogénea.

El segundo criterio se obtiene segmentando las regiones en la imagen de iris a partir de un modelo de contornos activos utilizando reducción de ruido y comparando la permanencia de las regiones de dos iris segmentadas usando el índice de Jaccard (cf Sección 3.2).

El proceso general se ilustra en la Figura 23. El modelo obtenido se basa en los trabajos analizados en el estado del arte [44], [47]. Representando la textura del iris en conjunto con las regiones extraídas entre dos texturas de iris se obtiene una representación más robusta para poder comparar bajo diferentes condiciones. En el modelo Figura 23 se establecen pesos asociados a cada criterio de comparación y tiene la diferencia con respecto a [36] de que no se necesitan realizar filtros gaussianos a diferentes escalas para extraer las regiones discriminativas.



Figura 23. Descripción del modelo propuesto.

El modelo obtenido para dos texturas de iris $H1$ y $H2$ matemáticamente puede representarse como:

$$C(H1, H2) = p1 * \frac{C_1(H1, H2)}{CTB} + p2 * C_2(H1, H2) \quad (3-6)$$

donde CTB es la cantidad de bloques locales en que se divide la textura del iris, C_1 indica el primer criterio de comparación (cf. Sección 3.1) y C_2 es el segundo criterio de comparación (cf. Sección 3.2). Este esquema de suma está basado en el presentado por De. Marcisco para reconocimiento de iris de texturas con ruido [44] y en otro trabajo donde se utilizan dos criterios de comparación para reconocimiento en ambientes no controlados [47]. Los valores $p1$ y $p2$ en (3-6) pueden tomar valores entre $[0, 1]$, $p1 = x$ y $p2 = 1 - x$, estos indican los pesos asociados a cada resultado de comparación. Los pesos establecidos fueron inicialmente de 0.5 para igualdad de criterio en ambos métodos. Un peso $p1$ o $p2$ mayor a 0.5 favorece a uno de los criterios de comparación y le resta decisión al otro. Con los pesos asociados a cada criterio es posible favorecer uno de los dos criterios si tenemos conocimiento a priori de las características de las capturas. Por ejemplo, si conocemos que la base de datos está libre de ruido entonces podemos favorecer el peso $p1$ debido a que la textura puede representarse mejor con LBP. Se conoce que los algoritmos para extraer características de textura no tienen buen desempeño cuando existen degradaciones en las imágenes (cf. Sección 2.5). Si las imágenes en la base de datos presentan condiciones no ideales y existe ruido entonces el primer criterio podría no ser tan discriminativo y en ese caso sería conveniente favorecer el criterio $p2$.

Los métodos $CLBP$ y LPQ se analizaron para extraer las características de textura debido a que presentan mayor poder discriminatorio en texturas como se evaluó anteriormente (cf. Sección 2.5). Los métodos $CLBP$ y LPQ son discriminativos y tolerantes a degradaciones en la imagen como desenfoque y cambios de iluminación. El método LPQ , aunque es el que mejor resultado

obtuvo en las evaluaciones, su vector resultante es de tamaño 256 elementos. Además, el método LPQ necesita transformar al espectro de Fourier la textura y luego extraer las características, lo que agrega otro paso y mayor complejidad. Con 256 elementos por bloques como se tiene un total de 32 bloques el vector final del primer criterio utilizando LPQ sería de 8192 elementos. Debido a que el método CLBP utiliza los vectores uniformes para el signo y la magnitud, su vector de características es de 114 elementos. Con 114 elementos por cada uno de los 32 bloques origina un vector final de 3648 utilizando el método CLBP. Ambos métodos son discriminativos y no tienen tanta diferencia en el reconocimiento de texturas desenfocadas (ver Tabla 4 y Tabla 5). Por la menor complejidad computacional, menor tamaño de vector final de características y similar resultado en los valores obtenidos en la evaluación de desenfoco, se escogió el algoritmo CLBP para el primer criterio del modelo propuesto.

Con este modelo es posible comparar imágenes de iris teniendo en cuenta ambos criterios (regiones y textura). Las comparaciones por bloques tienen la ventaja de que no se necesita que toda la textura del iris esté presente entre ambas imágenes [30]. Teniendo sólo parte de la textura con la suficiente cantidad de bloques que cumplan los criterios (cf. Sección 3.1.4) es posible afirmar que son similares. El índice Jaccard en el segundo criterio añade robustez a la comparación debido a que tiene en cuenta la permanencia de las regiones geométricas, así como la estructura topológica de las formas geométricas y la localización espacial de las formas.

4 Bases de datos

Las bases de datos han sido creadas en diferentes condiciones y permiten tener imágenes de iris para experimentos en diferentes entornos y así crear mejoras a los algoritmos de reconocimiento creados hasta la actualidad. Debido a que las condiciones que se han capturados las bases de datos son diferentes y varían (cámaras, distancia, espectro. etc.) lo permite que se puedan crear sistemas de reconocimiento más robustos.

Las evaluaciones de los métodos de reconocimiento de iris requieren de bases de datos para medir su desempeño. Cada modelo propuesto puede ser evaluado con bases de datos o con adquisiciones en tiempo real. Con propósitos de comparación de los modelos propuestos entre diferentes autores se han creado bases de datos públicas de referencia. Entre las bases de utilizadas en este trabajo están UPOL [88], UBIRIS [89], MBGC [90].

4.1 UPOL

La base de datos UPOL[89] fue creada originalmente en la Universidad de “*Palackýho and Olomouc*”. Es una base de datos libre de ruido de alta calidad capturada con un espacio de trabajo optométrico con el dispositivo óptico (TOPCON TRC50IA) conectado a una cámara SONY DXC-950P 3CCD. Como puede ser observado en la Figura 24 las imágenes son fáciles de segmentar por la zona oscura que rodea el iris. Las imágenes están en el espectro visible y se pueden observar en la Figura 24. Las condiciones de capturas que reducen el factor de ruido permiten concluir acerca de esa condición cuando es que se utiliza para medir el desempeño de los métodos de reconocimiento.

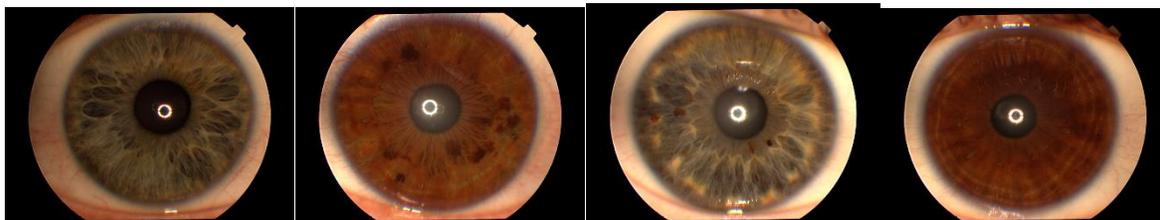


Figura 24. Base de datos UPOL.

4.1 UBIRIS

La base de datos Ubirisv1 fue creada en la Universidad de Beira Portugal. Las imágenes fueron adquiridas en dos sesiones diferentes Ubirisv1 y Ubirisv2 [89]. En ambas secciones se utilizó la

cámara Nikon E5700 en el espectro visible. En la primera sección de Ubirisv1 se minimizó el factor de ruidos provocado por reflexiones. Utilizaron una lámpara de halógeno detrás del dispositivo de captura en un cuarto oscuro. Esto permitió que se adquirieran imágenes más homogéneas en luminosidad y contraste. La sección de captura de Ubirisv1 adquirió 1877 imágenes de 241 personas.

La base de datos de la segunda sesión Ubirisv2 [89] fue capturada utilizando longitud de onda del espectro visible bajo factores de luminosidad natural. Se adquirieron 11,000 imágenes en Ubirisv2 con la mínima colaboración de las personas. La utilización de luminosidad natural adquirió imágenes con más reflexiones especulares, imágenes pobremente enfocadas en términos de contraste, brillo y obstruidas por parpados o pestañas.

Las imágenes de ambas sesiones (ver Figura 25) fueron clasificadas con respecto a tres condiciones (enfoque, reflexiones e iris visible) . Los resultados obtenidos manualmente por los autores fueron: Enfoque (Buenas=73.83%, Regular=17.53%, Malas=8.63%), Reflexiones (Buenas =58.87%, Regular =36.78%, Malas =4.34%), Iris visible (Buenas =36.73%, Regular =47.83%, Malas =15.44%).

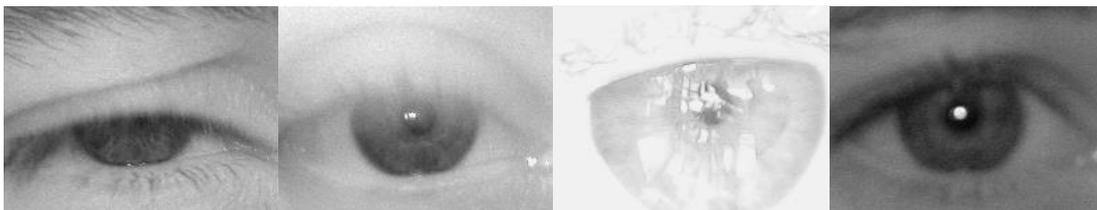


Figura 25. Imágenes base datos UBIRIS.

Es una de las bases de datos más apropiadas para evaluar los algoritmos en ambientes con ruido de acuerdo a un estudio [91].

4.2 MBGC

El principal objetivo de crear la base de datos MBGC [90] es tener adquisiciones de rostros e iris empleando imágenes fijas y de video en ambientes no controlados para investigar, evaluar y mejorar el desempeño de la tecnología de reconocimiento de personas. La base de datos fue adquirida a través de un Portal que consistía en un pasillo con arreglo de cámaras por donde la persona caminaba y se le iban adquiriendo las imágenes de rostros. Es útil para el reconocimiento de iris que presenten diferentes tipos de ruido debido a que las imágenes fueron capturadas en movimiento y a distancia. La base de datos MBGC [90] obtiene muestras frontales

y fueras de ángulo en imágenes en movimiento en interiores y exteriores utilizando una cámara infrarroja. El principal objetivo de MBGC [90] es poder investigar y mejorar el desempeño en el reconocimiento de rostros e iris con imágenes adquiridas a través del video en diferentes pose, iluminación y ángulos de la cámara. Las imágenes fueron capturadas en el espectro electromagnético del infrarrojo cercano entre 700 y 900 nm. En esta longitud de onda se minimizan las reflexiones de luminosidad que pudiera obstruir la región del iris, aunque tiene presencia de imágenes de iris con variación de iluminación.

4.3 Comparativa de condiciones de captura

Basado en el análisis de cada base de datos podemos realizar una comparativa en la que se resumen los factores de ruido de las condiciones no ideales de captura presentes en cada base de datos. En la Tabla 6 se resumen los diferentes factores de ruido donde el marcador (*) indica presencia del factor de ruido y (**) indica que la presencia del factor es crítica para obtener un buen reconocimiento.

Tabla 6. Base de datos comparativa.

Base de datos		UPOL	MBGC	UBIRIS
Longitud de onda		Visible	Infrarrojo	Visible
Factor de Ruido	Obstrucción de parpados	-	**	**
	Obstrucción de pestañas	-	**	**
	Desenfoco por movimiento	-	*	*
	Fuera de ángulo	-	**	*
	Iris parcial	-	*	*
	Pobremente enfocada	-	*	*
	Reflexiones especulares	*	-	**
	Iluminación	-	*	*

5 Esquema de evaluación del modelo propuesto

5.1 Grafica de distribución genuinas e impostoras.

Una comparación genuina es cuando se comparan texturas de iris pertenecientes a la misma persona. Como la textura del iris es diferente para los ojos, izquierdo y derecho de la misma persona (cf. Sección 2.1), en las comparaciones genuinas se debe tener en cuenta esta consideración. La grafica de distribución de las comparaciones genuinas se construye calculando la frecuencia de aparición del valor devuelto en la comparación (*score*) de muestras de texturas de iris iguales.

Las comparaciones impostoras por el contrario es comparar la textura del iris de personas diferentes o iris diferentes. La grafica de distribución se construye al calcular los valores con el resultado (*score*) de las comparaciones de texturas de iris diferentes. La gráfica representando ambas distribuciones puede observarse en la Figura 26. El umbral de corte permite establecer un valor para posteriormente hacer el reconocimiento.

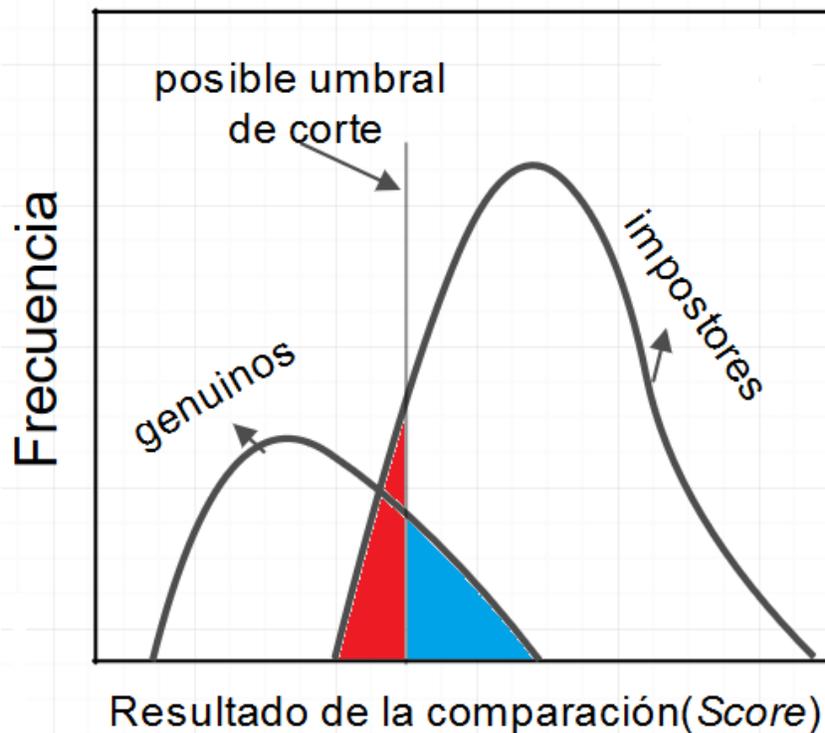


Figura 26. Graficas de los resultados de comparación.

5.2 Curvas características

Antes de definir las curvas características que nos permiten evaluar y comparar los algoritmos propuestos primero es necesario analizar los cuatro posibles resultados en un reconocimiento:

- Verdadero Positivo (VP). La comparación indicó que las texturas de iris eran de personas iguales cuando las texturas comparadas fueron de personas iguales.
- Verdadero Negativo (VN). La comparación indicó que las texturas de iris eran de personas diferentes cuando las texturas comparadas fueron de personas diferentes.
- Error 1. Falso Positivo (FP). La comparación indicó que las texturas de iris eran de personas iguales cuando las texturas comparadas realmente fueron de personas diferentes.
- Error 2. Falso Negativo (FN). La comparación indicó que las texturas de iris eran de personas diferentes cuando las texturas comparadas realmente fueron de personas iguales.

Las comparaciones genuinas que fueron correctamente clasificadas (cf. Sección 5.1) corresponden a los VP y las comparaciones impostoras correctamente clasificadas corresponden a los VN. Es deseable que siempre se obtengan valores VP o VN en el reconocimiento, pero no siempre el sistema de reconocimiento es perfecto y también pueden existir errores. En los posibles resultados de las comparaciones existen 2 tipos de errores en la clasificación, los falsos positivos FP o error tipo 1 y los falsos negativos FN o error tipo 2. La tasa de error de falsos positivos o falsa aceptación del inglés FAR (*False Acceptance Rate*) [92] se calcula como:

$$FAR = \frac{FP}{Total\ comparaciones\ impostoras} \quad (5-1)$$

La tasa de error de falsos rechazos del inglés FRR (*False Reject Rate*) [93] se calcula como:

$$FRR = \frac{FN}{Total\ comparaciones\ genuinas} \quad (5-2)$$

Basado en estos dos errores es posible calcular todas las comparaciones genuinas correctas del inglés GAR (*Genuine Acceptance Rate*) [94] como:

$$GAR = 1 - FRR \quad (5-3)$$

Una vez definido lo anterior se pueden construir las curvas características. Las curvas DET (*Detection Error Tradeoff*) [94], [95] grafican cada tasa FAR con su correspondiente FRR. En la curva DET mientras más cercanos a cero estén ambos errores es mejor el método de reconocimiento. La otra curva característica interesante para evaluar algoritmos es la curva ROC (*Receiver Operating Characteristic*) [96] la cual describe la tasa FAR con su correspondiente

GAR como se observa en la Figura 27. Cada línea en la Figura 27 es el resultado de cada método evaluado. Las líneas se construyen calculando el FAR y GAR para todos los posibles umbrales de corte de las distribuciones genuinas e impostoras (cf. Sección 5.1).

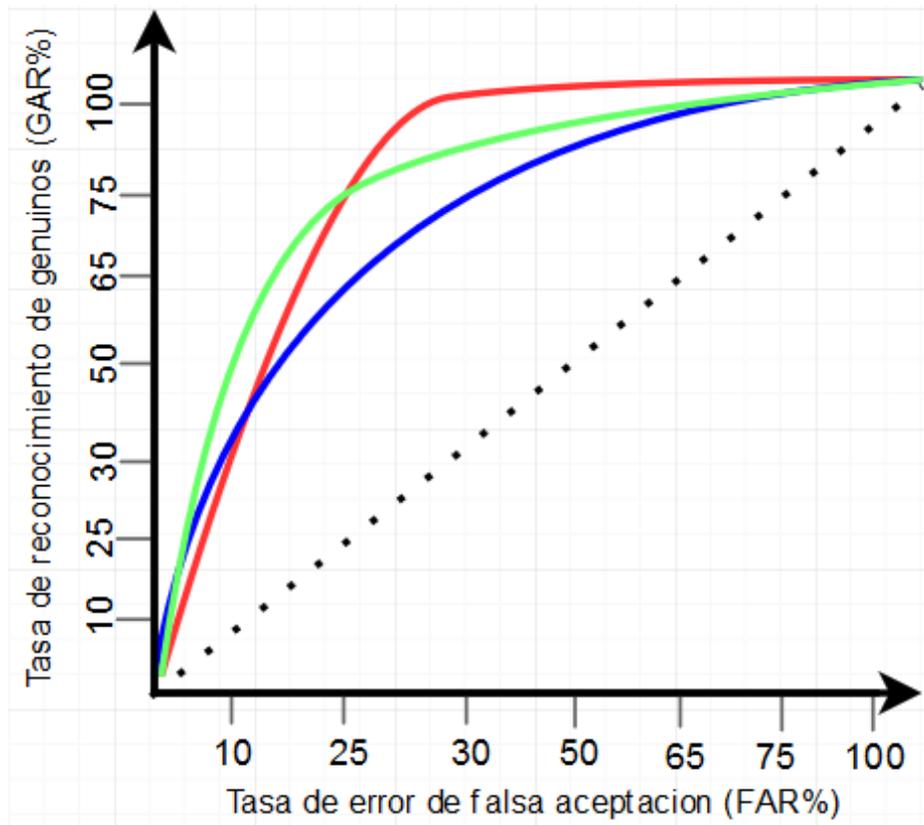


Figura 27. Curvas ROC de cada método de clasificación (líneas de color) evaluado.

Las curvas ROC han sido utilizada en diagnósticos médicos desde 1975 [97], sin embargo, cuando primero se utilizó para evaluar algoritmos de clasificación fue en el año 1989 [98]. Con la curva ROC se verifican los porcentajes de reconocimiento genuino correcto (GAC) al costo de tener un porcentaje de error de falsa aceptación (FAR). Un mejor método de clasificación es cuando la curva es más cercana al valor 1 de GAR. Una vez obtenida la curva ROC se pueden obtener otras medida de evaluación como por ejemplo el área bajo la curva (AUC) [99]. A mayor área bajo la curva el algoritmo de reconocimiento es más preciso. Para evaluar una prueba usando el espacio ROC también se utiliza la precisión, del inglés ACC(*Accuracy*) [100] y los valores predictivos negativos NPV del inglés (*Negative Predictive Value*) [101], [102] y predictivos positivos PPV del inglés (*Positive Predictive Value*) [101], [102].

5.3 EER (*Equal Error Rate*) e índice decisión (*d-index*)

La evaluación de métodos de clasificación y reconocimiento se pueden realizar determinando el grado de influencia en la precisión de la verificación. Para ello se utilizaron las métricas índice de igualdad de error o error de cruce, del inglés EER (*Equal Error Rate*) e índice de decisión [103]. El EER es la localización donde la tasa de falsos rechazos FRR(cf. Sección 5.2) es igual a la tasa de falsas aceptaciones FAR (ver Figura 28). Las curvas de error en la Figura 28 se obtienen desplazando el umbral de corte (cf. Sección 5.1) y calculando el FAR y FRR (cf. Sección 5.2) en cada posición.

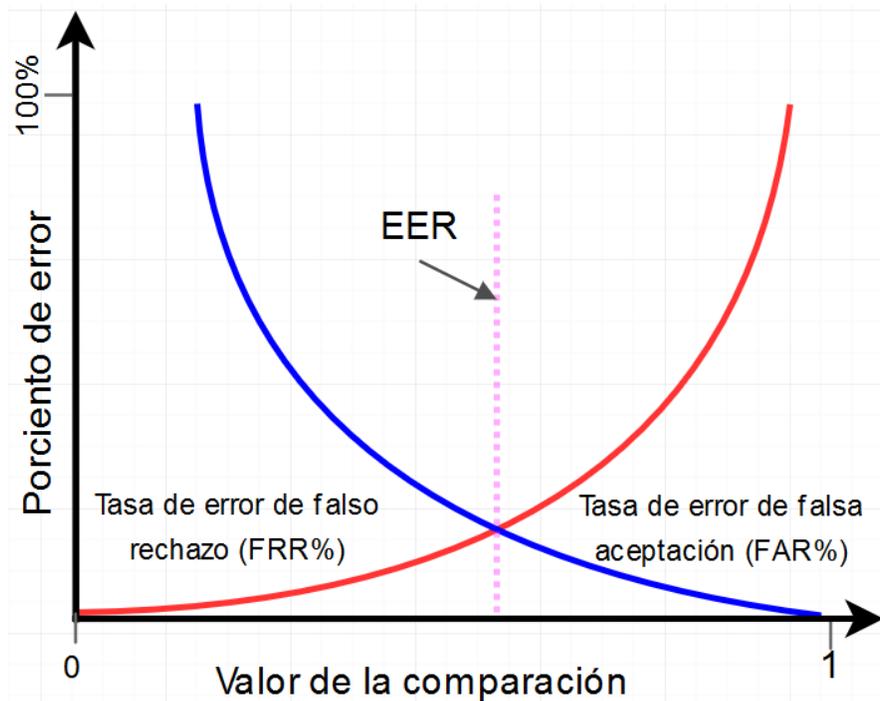


Figura 28. Distribuciones de comparaciones con tasa de igualdad de error (EER).

El valor indica la proporción de rangos de igualdad de error entre FAR y FRR, un valor menor indica mayor precisión en un sistema biométrico. El EER es único para dos distribuciones y sólo puede ser menor si ambas distribuciones están más separadas.

El índice de decisión por otra parte del inglés (*decidability index*) [103] es adquirido a través de dos distribuciones de distancias. La primera distribución de distancias corresponde a las comparaciones genuinas y la segunda distribución a las impostoras. Las distribuciones se calculan determinando la frecuencia de aparición de una distancia cuando se comparan dos texturas idénticas(genuinas) o diferentes(impostoras) (cf. Sección 5.1). No importa que valor se utilicen en las distancias pues el índice se calcula sólo teniendo en cuenta la frecuencia de

aparición identificando las comparaciones impostoras de las genuinas. La fórmula utiliza la media y la desviación de ambas distribuciones como se aprecia en la fórmula:

$$d' = \frac{|\mu_+ - \mu_-|}{\sqrt{\frac{\sigma_+^2 + \sigma_-^2}{2}}} \quad (5-4)$$

Donde μ_+ and σ_+^2 denotan el promedio y la varianza de comparaciones genuinas, y μ_- , σ_-^2 denotan la media y la varianza de comparaciones impostoras. El valor de la fórmula ayuda a determinar la distancia entre las dos distribuciones. Si ambas medias son aproximadamente iguales el numerador tiende a cero, esto indica que las distribuciones se solapan y esto no es un buen resultado pues no es posible determinar a partir de la distancia cuando se hace una comparación genuina o impostora. Un mejor resultado es cuando existe mucha distancia o alto valor de d' .

5.4 Metodología de comparación. Parte uno del modelo propuesto.

Una vez implementado el primer criterio de comparación visto en la sección 3.1 para extraer características de textura, la metodología consiste en evaluar el resultado y medir el desempeño del reconocimiento. Se utiliza el espacio ROC (cf. Sección 5.2) y la base de datos MBGC (cf. Sección 4.2). Se utilizan métodos para extraer las características de textura en los bloques con los métodos analizados (cf. Sección 2.3).

Se utiliza una modificación que se realizó al LBP base analizado en secciones anteriores (cf. Sección 2.3.1). La modificación al algoritmo es una optimización en C++ para ser utilizada desde Matlab a través de los archivos “*mex*” de Matlab, ver el Anexo2. Con esto fue posible utilizar el algoritmo LBP original desde Matlab, pero con una implementación realizada en C++ lo que agiliza la extracción de características.

Otra modificación realizada al algoritmo LBP original y denominada LBP PROM es la de actualizar valores simultáneamente en la salida del operador. Utilizar un valor de P mayor (cf. Sección 2.3.1) permite obtener las diferencias de un mayor número de características manteniendo el mismo tamaño de vector LBP original en 256 elementos. Se realiza un promedio de los píxeles centrales para obtener un único valor de g_c (cf. Sección 2.3.1) cada cuatro elementos centrales, lo que permite tener una salida con menos operaciones. Posteriormente se

calculan las diferencias entre los vecinos del nuevo valor g_c y se realiza una regla aritmética (5-5) para poder representar los valores obtenidos en un vector de 256 elementos.

$$\frac{\text{valor} * 255}{2^{P+1}} \quad (5-5)$$

Las obtenciones de los valores de esta forma se actualizan cada 4 píxeles por cada operación en vez de actualizar un sólo valor como en el LBP original.

Para la comparación por bloques del primer criterio (cf. Sección 3.1.4) se utilizan los métodos LBP U2, LBP PROM y se comparan con el LBP base (cf. Sección 2.3.1). La cantidad de divisiones de bloques se establecen como lo sugiere SUN [30] de tamaño 32x32 píxeles, 16 bloques en la parte superior y 16 bloques en la parte posterior de toda la textura del iris. En una textura de iris de 512 x 64 resultan una cantidad de 32 bloques diferentes. A mayor cantidad de bloques válidos utilizando el primer criterio de comparación (cf. Sección 3.1.4), es más alta la probabilidad de que las texturas de iris comparadas pertenezcan a la misma persona. En el proceso de extracción de características se utiliza pre procesamiento para ecualizar el histograma y realzar las características de textura. En la mayoría de los métodos analizados del estado del arte coinciden en que aplicar un realce en la textura del iris ayuda a mejorar el reconocimiento (cf. Sección 2.2). Se utilizó un método adaptativo de ecualizar el histograma AHE del inglés (*Adaptative Histogram Equalization*) [104].

En un primer experimento las muestras más representativas fueron obtenidas de forma visual en la base de datos MBGC (cf. Sección 4.2) de 30 clases y 5 muestras por clases. Lo anterior conlleva a que cada método a ser evaluado tenga que realizar un total de 11175 predicciones. La cantidad de comparaciones genuino e impostor se puede observar en la Tabla 7.

Tabla 7. Cantidad de comparaciones.

Clases, Muestras	Imágenes	Genuino	Impostor	Método
C30,M5	150	300	10875	LBP PROM
C30,M5	150	300	10875	LBP Base
C30,M5	150	300	10875	LBP U2

5.5 Metodología de comparación. Parte dos del modelo propuesto.

La metodología de comparación se enmarca en utilizar el segundo criterio de comparación del modelo propuesto (cf. Sección 3.2) y evaluar su desempeño. La metodología de comparación permite determinar si es factible hacer varias segmentaciones o no para extraer características de las regiones geométricas.

Antes de aplicar el método de segmentación se utilizó un método de realce de la imagen con el objetivo de mejorar el contraste en las imágenes. Se utilizó un método adaptativo de ecualizar el histograma AHE del inglés (*Adaptive Histogram Equalization*) [104]. Este método tiene la ventaja de que calcula varios histogramas, cada uno correspondiente a una sección distinta de la imagen, y los utiliza para redistribuir los valores de luminosidad de la imagen. En la mayoría de los métodos analizados del estado del arte coinciden en que aplicar un realce en la textura del iris ayuda a mejorar el reconocimiento (cf. Sección 2.2). Por tanto, es adecuado para mejorar el contraste local y la mejora las definiciones de bordes en cada región de la textura.

Se utilizó la segunda parte del modelo (cf. Sección 3.2) con la base datos de imágenes de iris MBGC analizada (cf. Sección 4.2). La cantidad de comparaciones genuinas e impostoras de los experimentos como los descritos en la Tabla 7 de la sección anterior (cf. Sección 5.4), lo que corresponde a 150 imágenes de textura tomados de la base de datos MBGC.

Para la evaluación es útil analizar la media y la varianza de los resultados de las comparaciones genuinas e impostaras obtenidos a partir del *score2* (cf. Sección 3.2.3). Evaluar además cada segmentación con su correspondiente curva ROC (cf. Sección 5.2) y obtener el área bajo la curva. Se realizaron un total de 7 experimentos. Los experimentos están resumidos y explicados en la Tabla 8.

Tabla 8. Descripción de los experimentos.

Número	Experimento	Descripción
1	3 segmentaciones	Se calculó la distancia J de cada comparación y se sumaron en un único valor. Se calculó la curva ROC.
2	Segmentación 1 y 2	Se sumaron los valores de las distancias J de cada comparación con la segmentación 1 y 2. Se calculó la curva ROC.
3	Segmentación 1 y 3	Se sumaron los valores de las distancias J de cada comparación con la segmentación 1 y 3. Se calculó la curva ROC.
4	Segmentación 2 y 3	Se sumaron los valores de las distancias J de cada comparación con la segmentación 2 y 3. Se calculó la curva ROC.
5	Segmentación 1	Se calculó la curva ROC de comparar usando sólo la segmentación 1
6	Segmentación 2	Se calculó la curva ROC de comparar usando sólo la segmentación 2
7	Segmentación 3	Se calculó la curva ROC de comparar usando sólo la segmentación 3

Los parámetros fueron variados tal que se pudieran obtener la mayor cantidad de regiones geométricas en la textura del iris. Se realizaron varias segmentaciones en las texturas de iris. En total se aplicó el método de Bresson [67] tres veces en cada imagen con diferentes valores en los parámetros para buscar los valores óptimos en la segmentación.

Los parámetros de la implementación del algoritmo de segmentación (cf. Sección 2.4.2) se describen en la Tabla 9. En una primera segmentación se estableció $\lambda=0.1$ y $\Theta=1$ como se indicó en el artículo original [67]. En otra segmentación se utilizaron valores cercanos a $\lambda=0.01$ y $\Theta=1$ y $\lambda=0.0001$ y $\Theta=0.5$ [67]. Los parámetros σ y β se mantuvieron fijos.

Tabla 9. Parámetros de modelo de Bresson.

σ (std_Gb)	Desviación estándar de la función gaussiana 2D usada para suavizar la imagen antes de aplicar el indicador de bordes (2-14)
β (beta)	Parámetro que controla la profundidad de la función de gradiente
Θ (theta)	Parámetro de regularización de la función u en el modelo ROF
λ (lambda)	Parámetro de segmentación de la función v
dt	Paso de tiempo para el esquema de minimización
IterUpd	Número de iteraciones

Como resultado de aplicar el método tres veces se obtienen tres imágenes lógicas que es el resultado de cada segmentación con diferentes parámetros. Cada segmentación se obtiene en menos de 5 segundos. Si el resultado de las segmentaciones es adecuado entonces las regiones geométricas que se obtienen en las texturas de iris son muy similares y deben permanecer para imágenes de la misma clase (ver Tabla 10). Por el contrario, las regiones que se segmenten en imágenes de texturas de diferentes clases deben de ser diferentes (ver Tabla 11). Por cada imagen segmentada se obtienen tres imágenes lógicas que es el resultado de cada segmentación. Con las imágenes lógicas obtenidas de dos muestras se pueden obtener el índice de J (cf. Sección 3.2.2). En los experimentos se evaluó si es adecuado hacer varias segmentaciones combinando el desempeño de las segmentaciones en cada uno de los experimentos.

Tabla 10. Las 3 segmentaciones de dos imágenes diferentes de la misma clase.

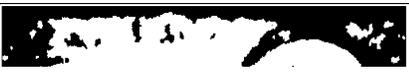
	Clase 1 Muestra 1	Clase 1 Muestra 2
Segmentación 1		
Segmentación 2		
Segmentación 3		

Tabla 11. Las 3 segmentaciones de 2 imágenes de clases diferentes.

	Clase 1 Muestra 1	Clase 2 Muestra 1
Segmentación 1		
Segmentación 2		
Segmentación 3		

5.6 Metodología de comparación del modelo.

La metodología de comparación del modelo evalúa el reconocimiento de iris usando el modelo propuesto (cf. Sección 3.3) en diferentes bases de datos de iris (ver Tabla 12), que fueron analizadas en la sección 4. Se analizó un trabajo donde se realiza una comparativa de métodos de segmentación de textura de iris para sistemas de alta fiabilidad. Entre los algoritmos que fueron evaluados y dieron buenos resultados en el trabajo analizado se encuentra el de segmentación de textura de iris Viterbi y WAHET (*Weighted Adaptive Hough and Ellipsopolar Transform*) [105]. Basado en los resultados de los métodos la base de datos UPOL fue segmentada y normalizadas con el algoritmo WAHET cuya implementación está en USIT⁴ para extraer la textura del iris. El método de extracción de la textura del iris en la etapa de pre-procesamiento es fundamental para un buen reconocimiento. Para no introducir imágenes sin textura de iris en los experimentos se procedió a descartar malas segmentaciones. Ejemplos de las segmentaciones requeridas para experimentos y las descartadas para la base de datos UPOL se pueden observar en el Anexo 3. Para las bases de datos MBGC y Ubiiris, se utilizó el método de segmentación Viterbi [105]. En estas bases de datos también se verificaron las segmentaciones y solo se utilizaron las que realmente tenían textura de iris. Ejemplo de la cantidad total de imágenes en cada base de datos y las que realmente se utilizaron en los experimentos lo podemos observar en la Tabla 12.

El modelo propuesto fue comparado con los algoritmos de extracción de características de los métodos analizados (cf. Sección 2.2), entre ellos Monro [33], Ko [34], Ma [22], Masek [42],

⁴ USIT - University of Salzburg Iris Toolkit v1.0, <http://www.wavelab.at/sources/>

Daugman [13] y Cr [40]. La implementación de los métodos de comparación están disponibles en USIT y OSIRIS⁵[106], ambos sistemas de software libre desarrollados con propósitos de investigación.

Tabla 12. Experimentos en diferentes bases de datos.

Base de datos	UPOL C64M6	MBGC C100M20	MBGC C30M5	UBIRIS C241M5
Total de imágenes	384	2000	150	1214
Total sujetos	64	100	30	241
Muestras izquierdas	3	20	5	5
Muestras derechas	3			
Total de imágenes utilizadas	188	1662	150	745
Total de comparaciones genuinas	143	7800	300	1276
Total de comparaciones impostoras	17231	1361200	10875	274377

Para verificar la robustez del modelo se realizaron experimentos variando el tamaño de los bloques (cf Sección 3.1.1) en la extracción de características de la textura del primer criterio de comparación del modelo (cf Sección 3.1). Al variar el tamaño de los bloques se realizan menos operaciones debido a que el descriptor utilizado (cf Sección 3.1) extrae las características de textura en todos los píxeles de los bloques de forma local y se descarta parte de la textura del iris. En trabajos anteriores estudiados en la literatura para la extracción de características de textura se han realizado con un 75% de la textura del iris más cercana a la pupila (cf. Sección 2.2). Se ha comprobado que en esa región las características sólo se extraen de la textura del iris en vez del párpado o las pestañas. Por ese motivo se realizaron experimentos reducción de tamaño de bloques en un iris y localizados en la zona más cercana a la pupila para extraer las características de textura del primer criterio (cf Sección 3.1). La cantidad de bloques se estableció fija de tamaño 32, los tamaños de los bloques fueron reducidos en filas hasta en un 74% del tamaño. En la Figura 29 se muestra la reducción del tamaño de los bloques por fila.

⁵ N. Othman, B. Dorizzi, y S. Garcia-Salicetti, “OSIRIS: An open source iris recognition software”

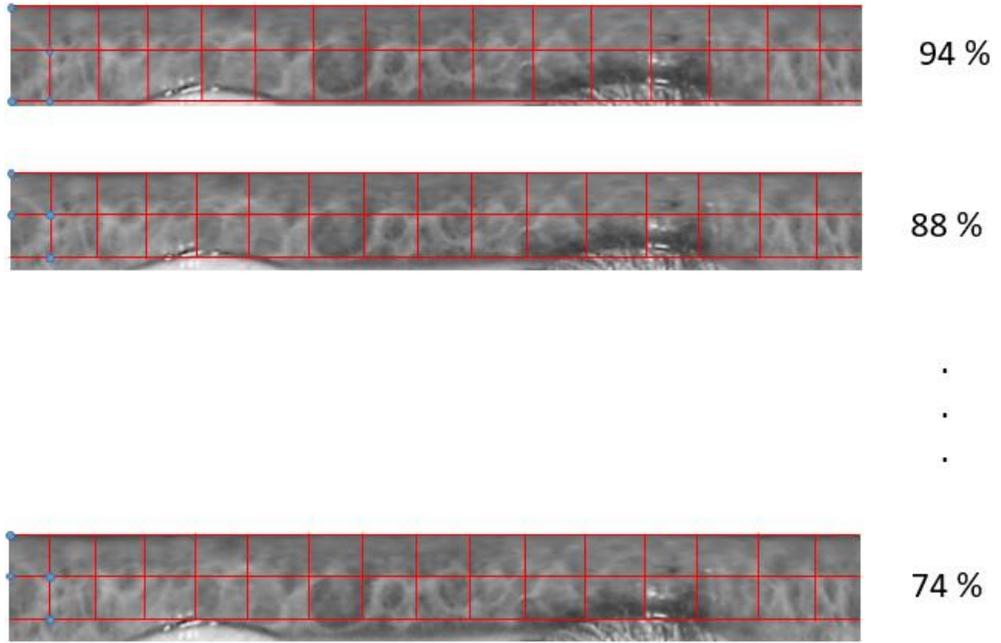


Figura 29. Reducción de tamaño de bloques.

6 Resultados experimentales

6.1 Análisis de resultados parte uno del modelo

Los resultados de los tres métodos de textura con la metodología para evaluar el primer criterio de comparación (cf. Sección 5.4) utilizando bases de datos de iris se puede observar en la gráfica de la Figura 30. Se muestran los resultados de los tres algoritmos implementados usando una colección de la base de datos MBGC de 30 clases con cinco muestras por clase.

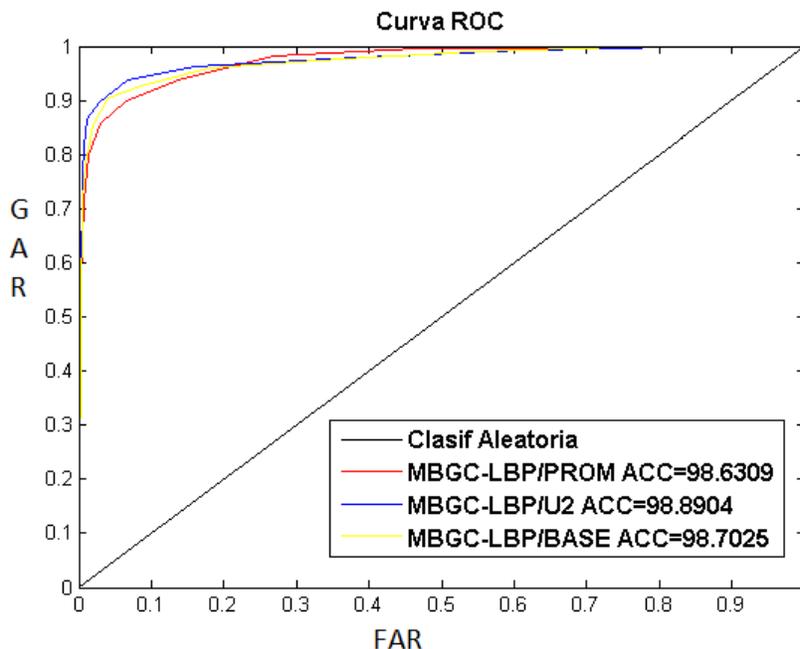


Figura 30. Comparaciones MBGC-C30S5.

Los resultados indican que todos los algoritmos permiten hacer el reconocimiento y los algoritmos LBP [49] tienen buen resultado para la base de datos MBGC. El mejor resultado fue el algoritmo LBP U2 [48] con una precisión del 98.89 %. Una de las ventajas de utilizar el LBP U2 es que el vector de características es de menor dimensión (cf. Sección 2.3.2), lo que disminuye el número de operaciones en la etapa de comparación, manteniéndose la precisión en el reconocimiento. El algoritmo LBP PROM obtuvo un similar resultado a los demás algoritmos con menor número de operaciones (cf. Sección 2.5.1). La gráfica de la Figura 30 indica que para un 10% de falsa aceptación los tres métodos tienen una tasa de reconocimiento genuino del 90%.

En la Tabla 13 se observa la precisión del método y un análisis de los valores predictivos (cf. Sección 5.2) del primer criterio de comparación para un umbral de decisión.

Tabla 13. Resultado de las comparaciones.

Clases, Muestras	VP	VN	PPV	NPV	ACC %	Tiempo seg	Método
C30,M5	215	10807	0.75	0.9922	98.63	198	LBP PROM
C30,M5	216	10814	0.78	0.9922	98.70	109	LBP Base [49]
C30,M5	245	10806	0.78	0.9949	98.89	81	LBP U2 [48]

El umbral de decisión fue seleccionado tal que los errores de tipo 1 (FP) y tipo 2 (FN) fueran iguales (umbral de corte EER ver cf. Sección 5.3). Si bien es viable hacer el reconocimiento con el método, el umbral de corte seleccionado de EER añade baja tasa de reconocimientos genuinos debido a que aumenta el error de tipo uno (cf. Sección 5.3). Los resultados indican que para este umbral en todas las implementaciones el método predice mejor una comparación impostora que una comparación de texturas genuinas. Esto quiere decir que cuando el método devuelve un *score* indicando que las texturas de iris no son iguales, en más de un 99% de las veces esto es cierto. Esto se evidencia por poseer todos los métodos un reconocimiento efectivo de impostores medido con la variable NPV (cf. Sección 5.2). Sin embargo, los métodos implementados con este enfoque tienen un reconocimiento de genuinos entre un 75% y un 81% medido con la variable PPV (cf. Sección 5.2).

6.2 Análisis de resultados parte dos del modelo

Se presentan los resultados de aplicar el segundo criterio de comparación (cf. Sección 3.2) bajo la metodología propuesta al hacer varios experimentos con diferentes segmentaciones (cf. Sección 5.5). El resultado de combinar tres segmentaciones lo podemos observar en la Figura 31. Se observa el valor con la frecuencia de aparición de las 300 comparaciones genuinas y 10875 comparaciones impostoras utilizando sólo el segundo criterio. Se puede verificar que existe diferencia entre las distancias cuando se comparan imágenes de una misma clase y cuando se comparan imágenes de textura de clases diferentes. Es evidente que el método discrimina para comparaciones genuinas e impostoras por la diferencia entre las medias y las desviaciones de ambas distribuciones. Al seleccionar un umbral de decisión en valor de distancia J se obtiene la precisión y errores en el reconocimiento.

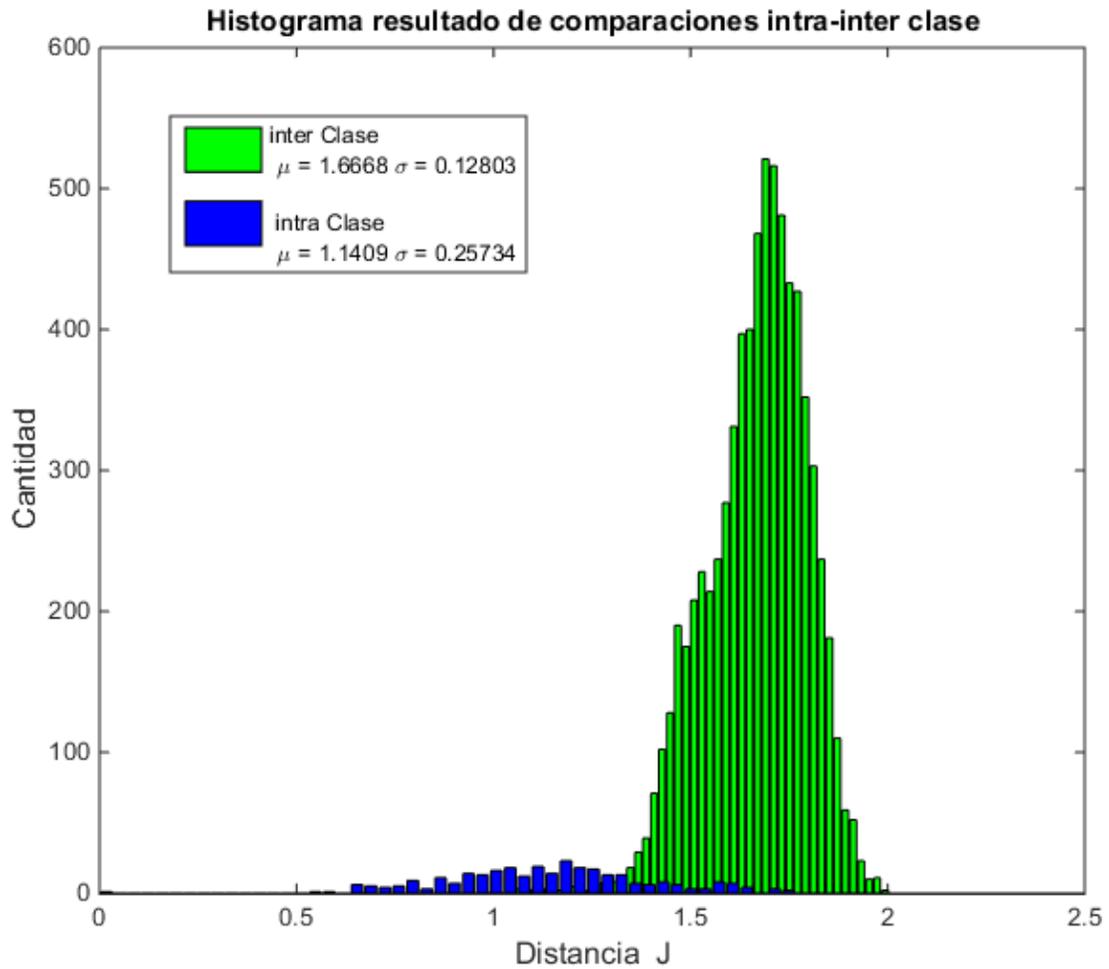


Figura 31. Distribución de las comparaciones experimento 1.

Con el objetivo de comparar las tres segmentaciones con los experimentos descritos anteriormente (ver Tabla 8) se realizó la comparación utilizando las curvas ROC. Se hicieron combinaciones de desempeño en el reconocimiento de las segmentaciones para determinar si es factible o no realizar varias segmentaciones. El primer método evaluado de color amarillo en la Figura 32 corresponde a sumar los índices J de las 3 segmentaciones como en la Figura 31. Con dicho método el área bajo la curva es de 0.9588. Éste experimento es superado cuando se dejan de sumar algunos de los dos valores de las otras segmentaciones 2 o 3. En los experimentos de sólo sumar el valor de distancia 1 y 2 (experimento 2) el AUC es del 0.9613 superando así el experimento 1. Si sumamos las distancias 1 y 3 (experimento 3) entonces el AUC es del 0.9618.

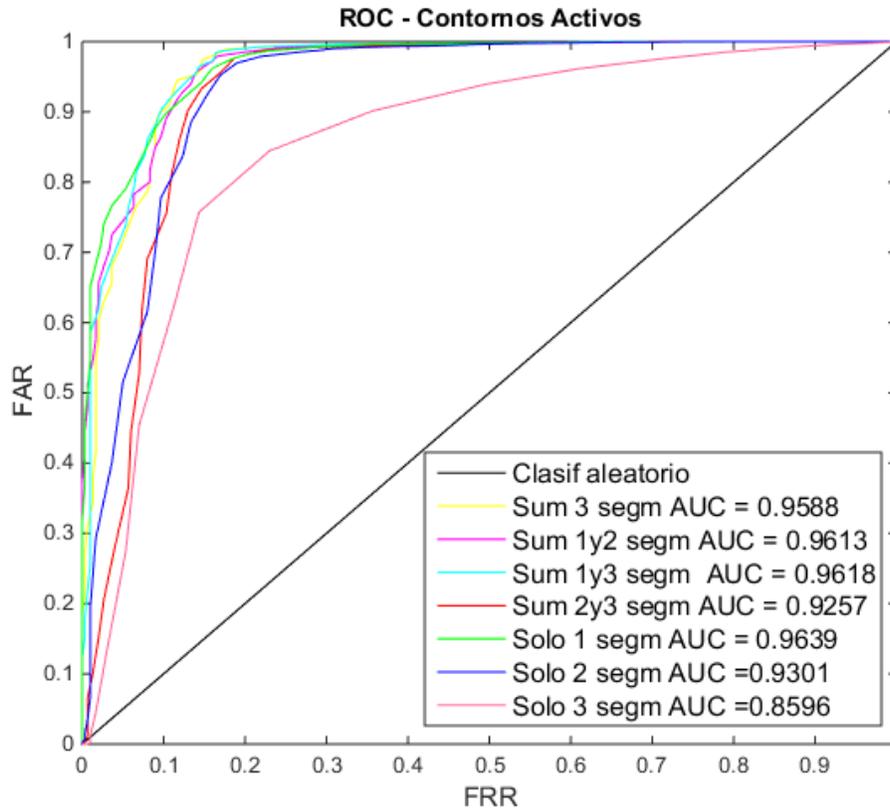


Figura 32. Resultado de las segmentaciones.

El mayor valor de AUC es obtenido en el experimento 5 donde sólo se utiliza la primera segmentación 1 AUC = 0.9639, gráfica de color verde. Más de una segmentación incurre en mayor tiempo de procesamiento y el desempeño es menor que si sólo utilizamos una segmentación. Debido al resultado del experimento 5 y los anteriores podemos concluir que con este método de comparación no es recomendable hacer varias segmentaciones. Sólo haciendo la segmentación del experimento 5 (cf. Tabla 8) se tienen menos tiempos de procesamiento y más precisión de las regiones geométricas segmentadas.

6.3 Resultados del modelo propuesto

En la Tabla 14 se obtienen los valores para cada base de datos utilizada y cada método comparado utilizando la metodología descrita en la sección 5.6. Se describen los resultados del modelo propuesto para diferentes bases de datos en el espectro visible e infrarrojo. Los resultados son comparados con otros algoritmos de extracción de características analizados en las búsquedas bibliográficas sobre modelado de textura del iris(cf. Sección 2.2). Los valores en

negrita de la tabla Tabla 14 resaltan los modelos de mejor desempeño en índice de decisión y tasa de error.

Tabla 14. Resultado del modelo propuesto.

Base de datos	MBGC C100M20		MBGC SUB-C30M5		Ubirisv1 Sesión 1		UPOL	
	EER (%)	d'	EER (%)	d'	EER (%)	d'	EER (%)	d'
Monro [33]	-	-	3.08	2.52	9.94	2.23	1.65	2.39
Ko [34]	-	-	11.0	2.46	11.4	2.09	1.4	3.44
Ma [22]	-	-	2.42	3.64	8.1	2.76	4.9	2.56
Masek [42]	3.32	3.64	2.38	3.98	8	3.12	1.4	4.19
Daugman [13]	3.71	3.34	-	-	-	-	-	-
Cr [40]	-	-	9.36	2.61	14.6	2.03	4.9	2.81
Criterio 1	-	-	10.1	2.57	10.1	2.48	7.0	2.63
Criterio 2	-	-	6.20	2.85	13.5	1.55	2.79	2.57
Modelo	5.60	2.55	4.48	3.11	9.4	2.59	0.88	3.58

Los resultados indican que el modelo propuesto presenta discriminación cuando es comparado con los otros modelos de reconocimiento usando las mismas bases de datos. En el Anexo 4 se presentan los resultados de las distribuciones de las comparaciones genuinas e impostoras utilizando el modelo propuesto para cada base de datos evaluada. Estos resultados muestran la separación de las distribuciones genuinas e impostoras tanto para las bases de datos libres de ruido (UPOL) y las adquiridas en condiciones menos controladas (UBIRIS, MBGC).

En la base de datos MBGC el modelo propuesto estuvo en tercer lugar de los cinco comparados, siendo superado por el algoritmo de Ma y Masek (ver Tabla 14). Podemos observar que para un EER = 4.48%, el modelo propuesto tiene un reconocimiento correcto de un 92% (ver Figura 33) en 11150 comparaciones de la base de datos MBGC de 30 clases y cinco muestras por clase. Si se aumenta el error de tipo uno indicando una falsa aceptación igual al 5% el modelo propuesto tiene un reconocimiento correcto de un 95% pero al costo de tener más falsas aceptaciones. En esta base de datos, el desempeño del criterio 2 estuvo por encima en índice de decisión

comparado con el criterio 1 del modelo. El índice de decisión del modelo $d = 3.11$ supera los valores obtenidos del criterio 1 con $d = 2.57$ y del criterio 2 con $d = 2.85$. Cuando se aumenta la cantidad de personas a 100 y con 20 muestras de textura de iris por cada persona el modelo tiene un EER = 5.60 con un reconocimiento de genuinos correctos del 90% (ver Figura 34) en 1 369 000 comparaciones.

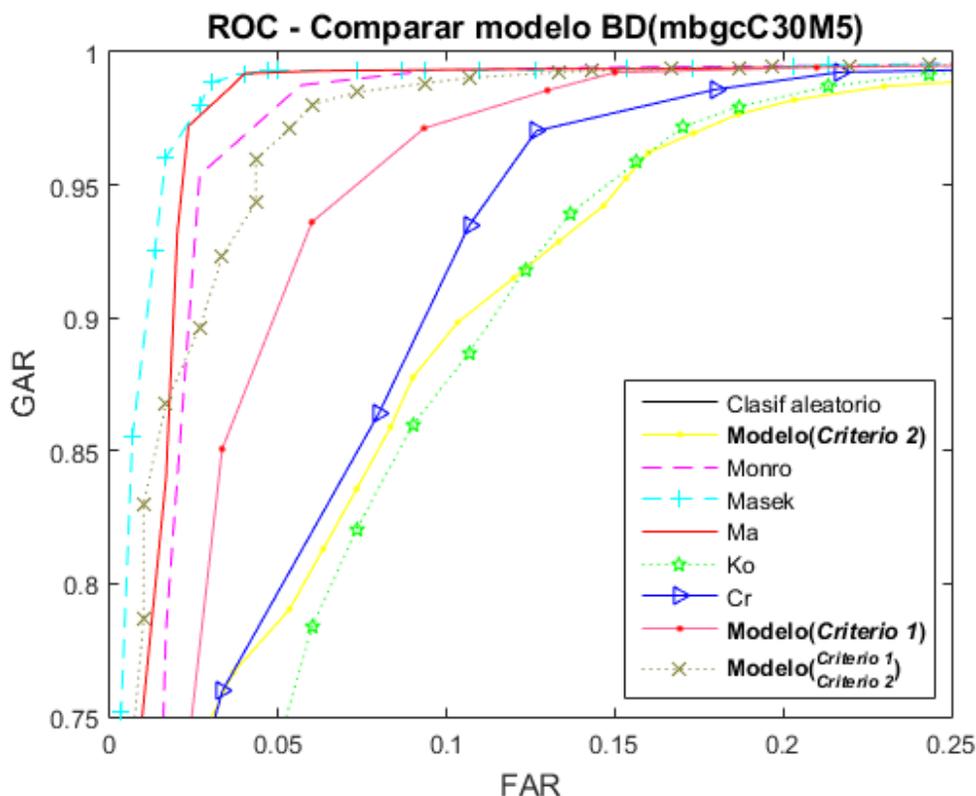


Figura 33. Curva ROC comparaciones de métodos en base de datos MBGC C30M5.

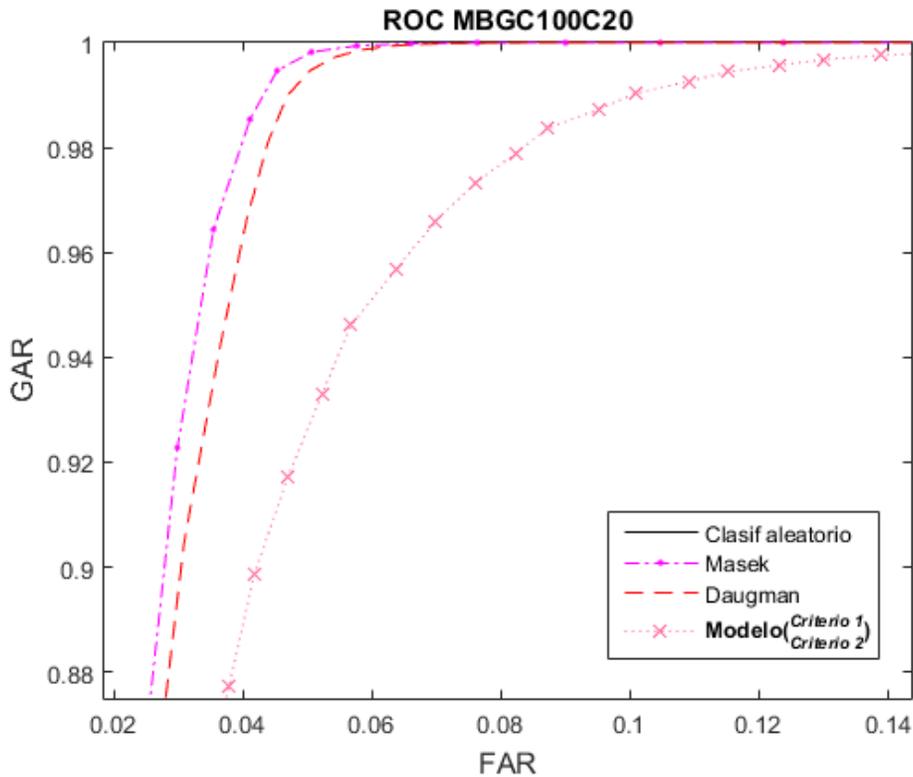


Figura 34. Curva ROC comparaciones de métodos en base de datos MBGC C100M20.

En la sesión uno de la base de datos Ubirisv1 el modelo propuesto estuvo por encima de los modelos (ver Figura 35) de Monro, Ko y Cr. El modelo estuvo por debajo en índice de decisión si los comparamos con los modelos de Ma y Masek (ver Tabla 14). Podemos observar que para un EER = 9.4%, el modelo propuesto tiene un reconocimiento genuino de un 90% en 274377 comparaciones de la base de datos Ubirisv1. Si aumentamos el error de tipo uno indicando una falsa aceptación igual al 13% el modelo propuesto tiene un reconocimiento correcto de un 95% pero al costo de tener muchas falsas aceptaciones. Todos los métodos comparados en el estado del arte con esta base de datos tampoco obtuvieron un buen desempeño en esta base de datos. En esta base de datos también el desempeño del criterio 1 estuvo por encima en índice de decisión comparado con el criterio 2 del modelo. El índice de decisión del modelo $d = 2.59$ supera los valores obtenidos del criterio 1 con $d = 2.48$ y del criterio 2 con $d = 1.55$.

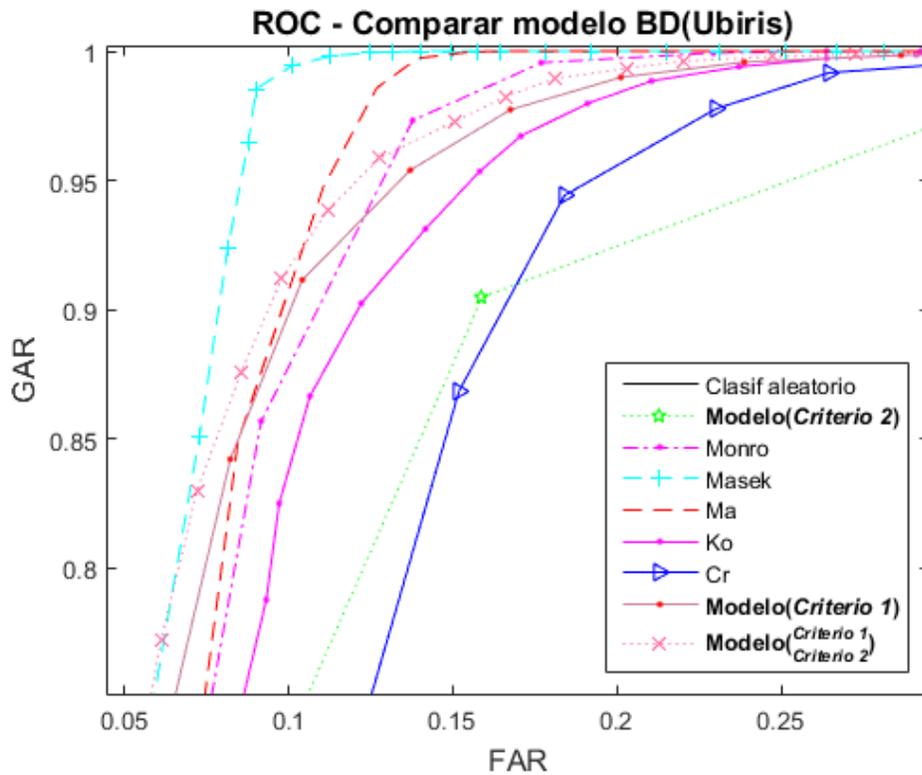


Figura 35. Curva ROC comparaciones de métodos en base de datos Ubirisv1.

En la base de datos UPOL el modelo propuesto estuvo en segundo lugar en índice de decisión siendo superado por el método de Masek (ver Figura 36). En esta base de datos el modelo propuesto tuvo el valor de EER más bajo que todos los demás modelos. Podemos observar que para un $EER = 0.88\%$, el modelo propuesto tiene un reconocimiento genuino de un 98% en las comparaciones de la base de datos UPOL. Su aumentamos el error de tipo uno indicando una falsa aceptación igual al 1.8% el modelo propuesto tiene un reconocimiento correcto genuino de un 99% pero al costo de tener un poco más de falsas aceptaciones. El primer criterio de comparación del modelo (cf. Sección 3.1) fue de los valores más altos en esta base de datos. Todos los métodos comparados en el estado del arte con esta base de datos obtuvieron un buen desempeño. Aunque esta base de datos está libre de ruido existían inconsistencias rotacionales de las texturas de iris y desalineaciones lo que afectaron un poco el desempeño de todos los métodos. La tasa de igualdad de error de todos los métodos estuvo cercana a 0 valor esperado para un excelente reconocimiento. En la base de datos libre de ruido UPOL la tasa de reconocimiento del primer método de comparación es de las más altas, con un índice de decisión (2.63)(ver Tabla 14), sin embargo, presenta un alto porcentaje de igualdad de error (7.0)(ver

Tabla 14). El primer criterio de comparación del modelo tuvo un índice de decisión de 2.63, y el segundo criterio de comparación del modelo tuvo un índice de 2.57. Ambos criterios fueron superados en el modelo final al combinarlos para un valor final de índice de decisión de 3.57 con un error de falsa aceptación y falso rechazo del 0.88%.

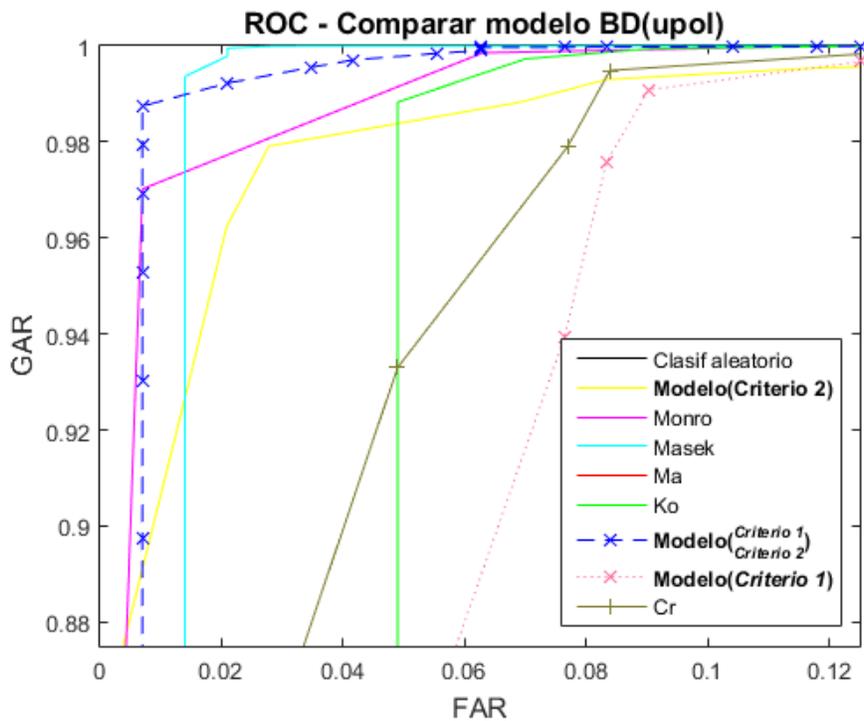


Figura 36. Curva ROC comparaciones de métodos en base de datos UPOL.

Con respecto a los experimentos de reducción de tamaño de bloques muestran que se mantiene el índice de decisión. Al reducir hasta un 80% el tamaño de los bloques(ver Figura 37) en el primer criterio (cf. Sección 3.1) se extraen las características más cercanas a la pupila. Esto es debido a que cuando se reduce el tamaño de los bloques se pierde información de la textura del iris en zonas donde se tiene presencia de párpados o pestañas. Si se reduce el tamaño de los bloques y se posicionan en zonas más cercanas a la pupila se mantiene el índice de discriminación y menor procesamiento para el reconocimiento.

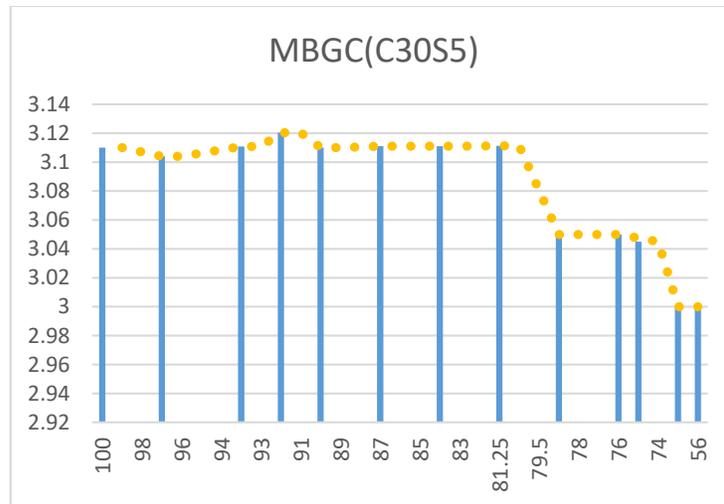


Figura 37. Resultado reducción de bloques.

Si se reduce demasiado el tamaño de los bloques la tendencia es que el resultado se aproxima a sólo tener en cuenta el criterio de comparación dos (cf. Sección 3.2).

6.4 Conclusiones

Los resultados experimentales reflejan que el modelo propuesto usando la combinación de ambos criterios (criterio 1 y criterio 2) de comparación provee una mejor tasa de reconocimiento que al utilizar algunos de los criterios 1 y 2 de manera individual.

En el criterio dos del modelo, el índice de Jaccard permitió evaluar la permanencia de las regiones geométricas obtenidas de la segmentación. Utilizando el índice de Jaccard no es necesario aislar las regiones. Si se desea evaluar la permanencia de las regiones de forma aislada, será necesario buscar otro método de evaluación.

Se mejora el desempeño del reconocimiento cuando se combinar la extracción de características de textura junto con las formas geométricas. Esto afirma que tener dos tipos de métodos con diferentes criterios para extraer características ofrece mejor resultado en el reconocimiento. En la base de datos UPOL libre de ruido el método propuesto fue el que obtuvo menor tasa de error, esto es porque la característica de textura del primer criterio de comparación pudo extraerse bien en una base de datos libre de ruido. Este resultado confirma lo obtenido por SUN [30] debido a que en este trabajo también se utilizan los patrones locales binarios.

En la base de datos Ubrivsv1 con más requisitos en cuanto condiciones de ruido, el modelo propuesto mantiene similar discriminación con los métodos de extracción de características para

reconocimiento de iris de la bibliografía. El método propuesto obtuvo buenos resultados para subconjuntos de MBGC, con 5% de falsas aceptaciones para un reconocimiento genuino del 95%. El modelo propuesto estuvo por debajo en el reconocimiento si lo comparamos con los algoritmos de Daugman y Masek cuando se realizaron más de un millón de comparaciones, aunque no estuvo tan alejado el índice de decisión. La técnica de reducción del tamaño de los bloques en la textura del iris permitió disminuir el procesamiento manteniendo el índice de discriminación.

7 Conclusión general

La tecnología del reconocimiento biométrico de personas basado en iris no es totalmente nueva. Sin embargo, se ha prestado más atención a la utilización de esta tecnología en la actualidad debido a que los sistemas de reconocimiento de personas basados en iris están siendo utilizados en cajeros automáticos y en dispositivos móviles. Desde el surgimiento del primer sistema han venido apareciendo retos para lograr un mejor reconocimiento. Los primeros sistemas estaban limitados a condiciones de capturas con cooperación del usuario, lo que representa una problemática para reconocer a distancia o con presencia de ruidos. Estuvieron orientados a obtener la textura del iris libre de parpados o pestañas haciendo mejoras en la etapa de adquisición y pre procesamiento. En cambio, otros aportes y que son de interés en este trabajo estuvieron más orientados a obtener una mejor representación por la localización inexacta o problemas de oclusión y contraste en las texturas del iris adquiridas. Esto debido a que en etapas anteriores como la adquisición o el pre procesamiento no fue adquirido toda la textura del iris o se presentaron mayor variabilidad por los tipos de ruidos presentes (cf. Sección 1.1).

Para solucionar esta problemática se analizaron métodos de extracción de características por diferentes autores que mejor permiten representar las variaciones dentro de la textura de un iris. Entre los métodos analizados podemos resaltar los descriptores de características que permiten representar el contraste en la textura y son invariantes a cambios de iluminación. Estos métodos analizados se evaluaron en reconocimiento de texturas con diferentes niveles de desenfoque. La evaluación realizada permitió que se obtuvieran los métodos descriptores de textura discriminativos y robusto bajo condiciones de desenfoque y contraste. Se analizaron además otros métodos para describir la textura de iris basado en aproximaciones geométricas. Esta representación permitió obtener las formas geométricas que permanecen en la textura de los iris (cf. Sección 2.6). Con los métodos analizados fue posible construir un modelo que para reconocer los iris de las personas a partir de las regiones geométricas que se encuentran dentro de la textura. Las regiones geométricas pudieron obtenerse aun cuando había presencia de ruido (cf. Sección 3.3). Este modelo es robusto en cuanto a oclusión debido a que no toda la textura del iris se necesita para hacer el reconocimiento. Fue posible reconocer los iris de las personas utilizando bases de datos públicas adquiridas a distancia, en movimiento y en otras condiciones donde está comprometida la información de la textura del iris en la etapa de extracción de

características (cf. Sección 2.2). Al analizar las bases de datos públicas de reconocimiento de iris se observó que existían algunas que no representaban las condiciones reales de un sistema de captura como por ejemplo la UPOL. En lugar de esta base de datos también se analizaron otras como la UBIRIS y la MBGC que representaban mejor la realidad de un sistema de adquisición real de imágenes de ojos (cf. Sección 4). Las bases de datos fueron utilizadas como parámetros para evaluar y comparar los sistemas de reconocimiento analizados en la literatura con el modelo que se propuso para el reconocimiento. La mayoría de los métodos que fueron analizados en la bibliografía (cf. Sección 2.2) se basaron en utilizar un criterio de extracción de características para comparar imágenes de iris de las personas. La utilización de sólo un método de extracción de características limitaba el desempeño del reconocimiento del método que utilizaban los diferentes autores. Aunque existían métodos para comparar iris a partir de varios criterios ninguno utiliza la información de las regiones geométricas presentes dentro de la textura del iris. En el modelo propuesto se tiene en cuenta las regiones geométricas obtenidas y las variaciones de intensidad dentro de la textura del iris. Se basó en dos criterios de comparación que utilizan diferentes métodos para la extracción de características a diferencia de la mayoría de los métodos propuestos en la literatura. Las regiones geométricas fueron obtenidas con el algoritmo de contornos activos, estas se pueden representar, aunque exista ruido en las formas dentro de la textura. Se pudo comprobar la permanencia de las regiones geométricas segmentadas entre imágenes de una misma persona e imágenes de personas diferentes a partir del índice de Jaccard. Los resultados para evaluar la exactitud del modelo discriminan de forma positiva en la base de datos MBGC con un 5% de tasa de falsa aceptación para reconocer un 95% de iris genuinos en la base de datos MBGC con 30 personas y 5 muestras de textura de iris por persona. Cuando se aumentó la base de datos a 100 personas con 20 muestras por cada persona y se realizaron más de un millón de comparaciones, en ese caso el error de falsa aceptación subió a 5.6% y el porcentaje de reconocimiento genuino bajó a un 90%. La base de datos MBGC del espectro infrarrojo ofreció buenos resultados si la comparamos con los otros algoritmos de reconocimiento analizados en la literatura, como es el caso de Ko [34], Cr [40], Monro [33]. El método de Masek [42] que es basado en único criterio ofreció los mejores resultados en las bases de datos con presencia de muchos factores de ruido y es el mejor algoritmo que discrimina en cuanto a condiciones no controladas según los resultados experimentales. Sin embargo, utilizando el modelo propuesto en la base de datos UPOL se tuvo

una igualdad de error del $EER = 0.88\%$ lo que es un buen reconocimiento para una base de datos completamente libre de ruidos superando todos los demás modelos incluido el método de Masek el cual tuvo un porcentaje de error del 1.4% .

7.1 Contribuciones del trabajo de tesis

La principal contribución del trabajo de tesis estuvo en obtener un modelo para reconocer las texturas de iris basado en las formas geométricas e información del contraste evaluado en bases de datos de los espectros visible e infrarrojo.

La evaluación de diferentes métodos de extracción de características de textura bajo diferentes niveles de desenfoque en bases de datos de textura permitió obtener los métodos más discriminativos de los analizados en la literatura y fueron utilizados en el modelo final propuesto. El desenfoque es un tipo de ruido presente en las texturas de iris cuando se captura en movimiento o a distancia, con la evaluación de los métodos bajo esta condición fue posible seleccionar los métodos más discriminativos. El método de extracción de características utilizado permitió cuantificar las variaciones de contraste con la ventaja de ser invariante a cambios de iluminación homogénea.

La segmentación a partir de contornos activos proporciona una nueva representación de las formas geométricas que se encuentran dentro del iris. Con la utilización del método de reducción de ruido en conjunto con los contornos activos geométricos se tiene la ventaja de obtener las formas que permanecen aún con presencia de ruido. Se aportó además la utilización de un nuevo criterio basado en distancia Jaccard para la comparación de formas geométricas segmentadas para verificar la permanencia de las regiones geométricas obtenidas en dos texturas de iris.

La combinación de técnicas de extracción de características por variaciones de contraste invariante a iluminación homogéneo en conjunto con las regiones geométricas segmentadas sin importar ruido es un nuevo enfoque que añadió robustez al modelo final obtenido. El modelo final obtenido obtuvo una tasa de falsa aceptación del 5% para reconocer un 95% de iris genuinos, obtenidos de evaluar en la base de datos MBGC del espectro infrarrojo en la base de datos de 30 personas y 5 muestras de textura de iris por cada persona. En bases de datos del espectro visible también se logró el reconocimiento.

7.2 Trabajo Futuro

Debido a que se desarrolló un modelo de extracción de características para reconocimiento biométrico de iris y se evaluó utilizando bases de datos, el siguiente paso sería hacer el reconocimiento utilizando todo el sistema biométrico y con adquisiciones en tiempo real. Se podría además utilizar con capturas obtenidas a distancia o en condiciones similares a las bases de datos evaluadas. Sería interesante además utilizarlo cuando se combinen imágenes en múltiples espectros. Fusionando las imágenes se podrían obtener una textura más rica del iris lo que podría aumentar las formas geométricas y mejorar el reconocimiento del método propuesto. La fusión podría hacerse entre diferentes sensores con varias cámaras de adquisición o utilizando un sólo sensor y fusionando adquisiciones para determinadas longitudes de onda del espectro. La fusión de imágenes de la textura de iris también puede ser realizada en capturas obtenidas de diferentes longitudes de onda. Se podrían fusionar también con otros algoritmos de reconocimiento de iris, rostro o voz, a este tipo de sistemas se le llama multimodales. Lo anterior es un campo que actualmente se está explorando y el método podría tener un buen desempeño bajo este nuevo enfoque.

7.3 Seguimiento y mejoras

El modelo obtenido permitió discriminar entre texturas de iris y fue evaluado utilizando bases de datos en dos espectros infrarrojo y visible. Las mejoras podrían estar en el segundo criterio de comparación que utiliza el índice de Jaccard para evaluar la permanencia de las regiones segmentadas aun cuando las formas geométricas que se obtengan en la textura varíen. De acuerdo a lo anterior, se podría utilizar un criterio que permita comparar cada forma geométrica segmentada utilizando algún método de selección de las formas que permanecen. La mejora en este criterio podría utilizar algún otro método descriptor basados en contorno de la forma o propiedades topológicas como las analizadas en (cf. Sección 2.4.3). Los métodos implementados para extraer características de la textura del modelo sólo tienen en cuenta información espacial de la textura y las regiones geométricas que se segmentan, por tanto, otra de las mejoras podría estar en utilizar algún método de extracción de características que mejoren la representación de las formas geométricas tanto en espacio como en frecuencia. Se podría corregir además la etapa de comparación para que haga corrimientos en la textura y tenga en cuenta las desalineaciones de las texturas de iris. Aunque las comparaciones se realizaron lo

más equitativas posibles, en ninguno de los métodos se tuvo en cuenta inconsistencias en las rotaciones de las texturas de iris. Aunque para dos texturas de iris se deben de hacer varios corrimientos en las texturas y obtener el mejor valor de *score*, en ninguno de los métodos que se compararon del estado del arte ni en el propuesto se realizó. Las correcciones en las comparaciones pertenecen a la etapa de comparación dentro de todo el sistema de reconocimiento iris (cf Sección 1.3) y fue propuesto por Daugman. Las correcciones influyen y son necesarias para un mejor desempeño, aún sin las correcciones se obtuvieron buenos resultados en bases de datos con ruido y libres de ruido, sin embargo, no fue del todo contemplado en el presente trabajo.

Anexos

Anexo 1

El método SIFT del inglés (*Scale Invariant Feature Transform*) fue primeramente utilizado para el reconocimiento de objetos en imágenes [107] y publicado originalmente en el año 1999 [108]. El algoritmo extrae las características distintivas locales de una imagen usando un detector para conformar el descriptor. El detector encuentra en la imagen puntos de interés que están localizados en variaciones de intensidad de la imagen. El detector SIFT es robusto y detecta las mismas variaciones cuando las imágenes tienen diferentes condiciones de captura como puede ser diferente perspectiva, iluminación o escalado. La detección de puntos de interés se realiza con restas (diferencia) luego de aplicar un suavizado gaussiano, con diferentes parámetros σ (desviación de la gaussiana) y a diferentes escalas. Las diferencias entre dos imágenes suavizadas con un filtro gaussiano creciente es una aproximación al operador Laplaciano de Gauss [108] debido a que tiene fuerte respuesta positiva en zonas oscuras y respuestas negativas en zonas claras. Para describir un ejemplo del método se muestra una imagen sintética con formas geométricas circulares a diferentes escalas que se desean detectar para su descripción (ver Figura 38).

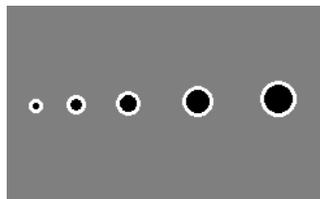


Figura 38. Imagen de ejemplo para algoritmo SIFT.

Luego de aplicar las diferencias gaussianas DoG a diferentes escalas de la imagen (ver Figura 39) se observa que la respuesta a las diferencias en las primeras escalas tiene mayor respuesta en regiones oscuras pequeñas. Al aumentar la escala y la σ en las diferencias gaussianas entonces la respuesta más fuerte está en las zonas oscuras con las diferencias que ocupan mayor cantidad de píxeles en la imagen (regiones grandes).

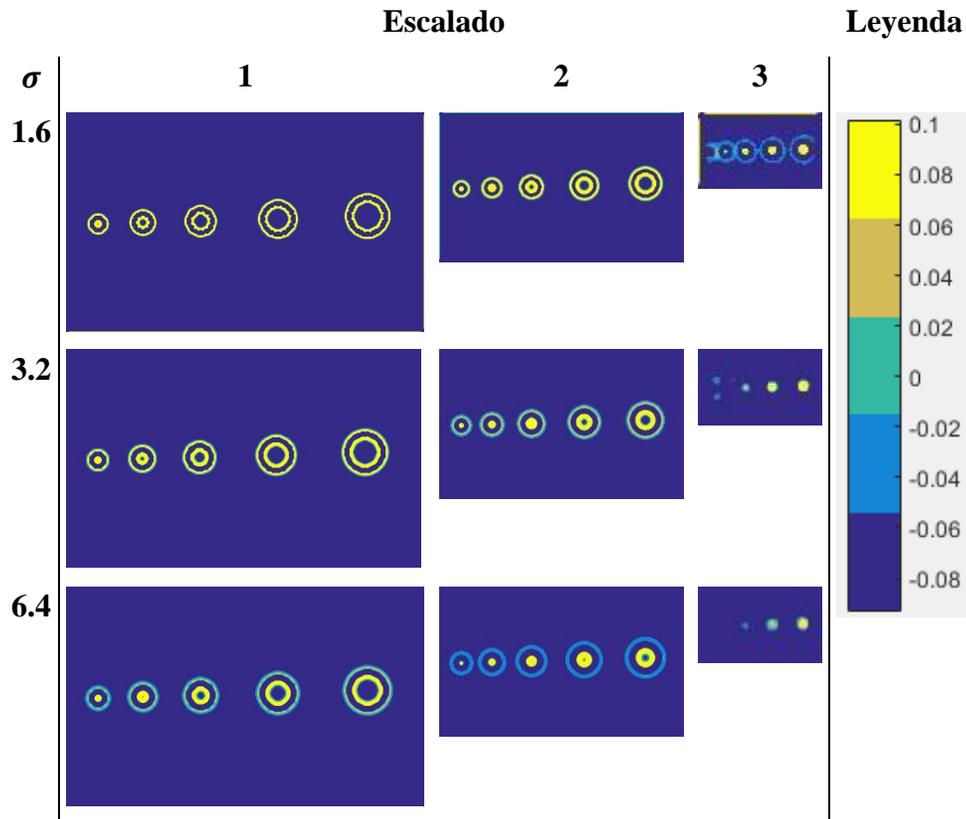


Figura 39. Diferencias gaussianas (DoG).

El detector de SIFT extrae puntos de interés máximos o mínimos en el espacio de diferencias gaussianas a diferentes escalas. En la Figura 40 podemos observar un ejemplo de los puntos detectados con el operador DoG de SIFT para la Figura 38.

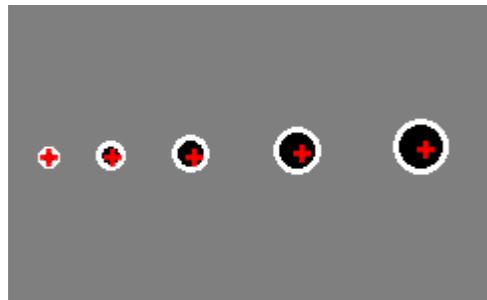


Figura 40. Puntos detectados del algoritmo SIFT.

Una vez que se detectan puntos locales de interés el proceso de descripción consiste en tomar muestras cercanas a la zona detectada y representarlas para poder hacer comparaciones. Debido a que en las primeras escalas y pequeños valores de σ detectan las manchas oscuras pequeñas se establece una región pequeña para describir la región (ver Figura 41). Las manchas más

grandes son detectadas en escalas y σ mayores, es por ello que la región para describir la característica debe de ser mayor (ver Figura 41).

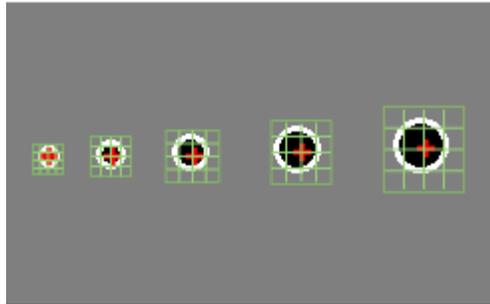


Figura 41. Región cercana a la característica detectada.

Basándose en una región centrada en la característica local detectada (ver Figura 41) se construye un descriptor con el histograma de las orientaciones de gradiente dominantes [109]. El resultado de aplicar el descriptor en cada punto de interés es un vector cuyas características son invariantes a escalados, traslaciones, rotaciones y parcialmente invariante a cambios de iluminación [108].

Anexo 2.

```
#include "mex.h"
#include "matrix.h"
#include "math.h"
#include <iostream>
#include <string.h>
#include <stdlib.h>
using namespace std;
int* LBP8(const int* data, int rows, int columns){}
/*int nlhs: número de argumentos de salida de la función
  mxArray *plhs[ ]: Matlab trabaja con un tipo de dato conocido como mxArray, similar
  a una estructura en el que además de contener el valor de la variable, contiene sus
  dimensiones como filas y columnas, si es formato double o si la variable es de tipo
  complejo.
  plhs[ ] es un arreglo de punteros, que precisamente apunta a las variables presentes
  en el lado izquierdo (que esperan los valores que regresará función.
  int nrhs: contiene la cantidad de argumentos que son entregados a la función
  mxArray *prhs[ ]: este al igual que *plhs[ ] también un arreglo de punteros, que en
  este caso apunta a las variables del lado derecho, que son las variables de tipo
  mxArray por defecto.*/
void mexFunction(int nlhs, mxArray *plhs[], int nrhs, mxArray * prhs[]){
int i,j,R,C,T ,M,N;
if(nrhs < 3 || nlhs > 1){ /* number of arguments */
  mexErrMsgTxt("Wrong number of input arguments. Must be input 3 and output 1 ");
return;
}
if(!IS_REAL_2D_FULL_DOUBLE(prhs[0])){
  mexErrMsgTxt("A must be a real 2D full double array."); return;
}
if(!IS_REAL_SCALAR(prhs[1])){
  mexErrMsgTxt("Arg 2 must be a real double scalar. Row"); return;
}
```

```

}
if(!IS_REAL_SCALAR(prhs[2])){
    mexErrMsgTxt("Arg 3 must be a real double scalar. Col"); return;
}
R = mxGetScalar(prhs[1]); C = mxGetScalar(prhs[2]);
double *data_d = (double *)mxGetData(prhs[0]);
int* image = new int[R*C];
for(i=0;i<R*C;i++){
    image[i] = data_d[i];
}
int* data; data = LBP8(image, R, C);
//tamaño del histograma
T = 256;
const mwSize dims[]={T};
unsigned char *start_of_pr;
size_t bytes_to_copy;
//Salida del vector
plhs[0] = mxCreateNumericArray(1,dims ,mxINT32_CLASS,mxREAL);//or mxCOMPLEX.
//plhs[1] = mxCreateDoubleScalar(R);
//plhs[2] = mxCreateDoubleScalar(C);

start_of_pr = (unsigned char *)mxGetData(plhs[0]);
bytes_to_copy = T * mxGetElementSize(plhs[0]);
memcpy(start_of_pr,data,bytes_to_copy);
}

```

Anexo 3

Tabla 15. Segmentación requerida en evaluaciones.

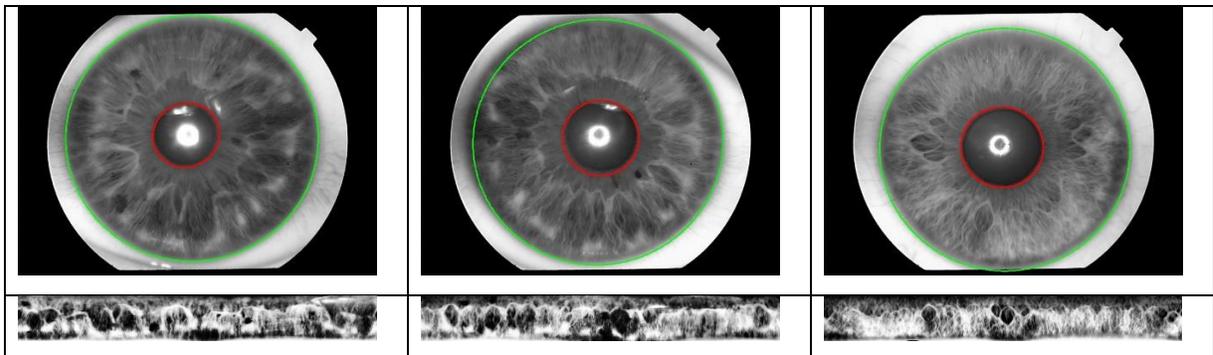
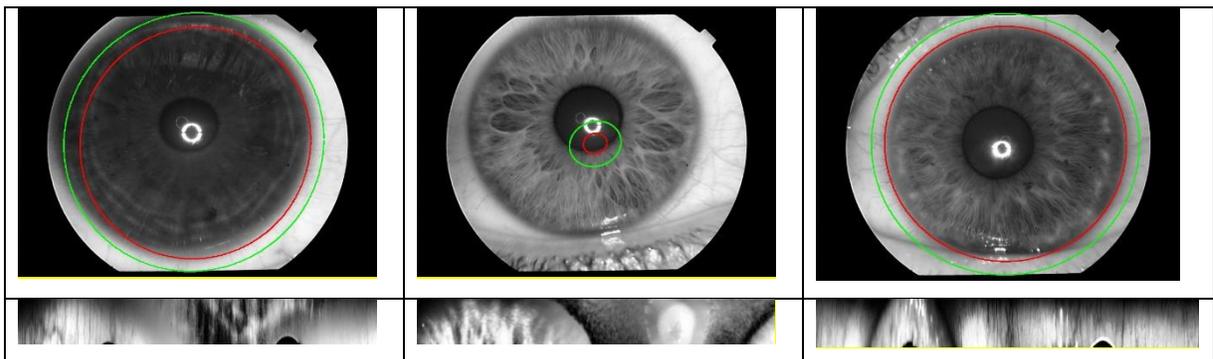


Tabla 16. Segmentaciones descartadas en evaluaciones.



Anexo 4

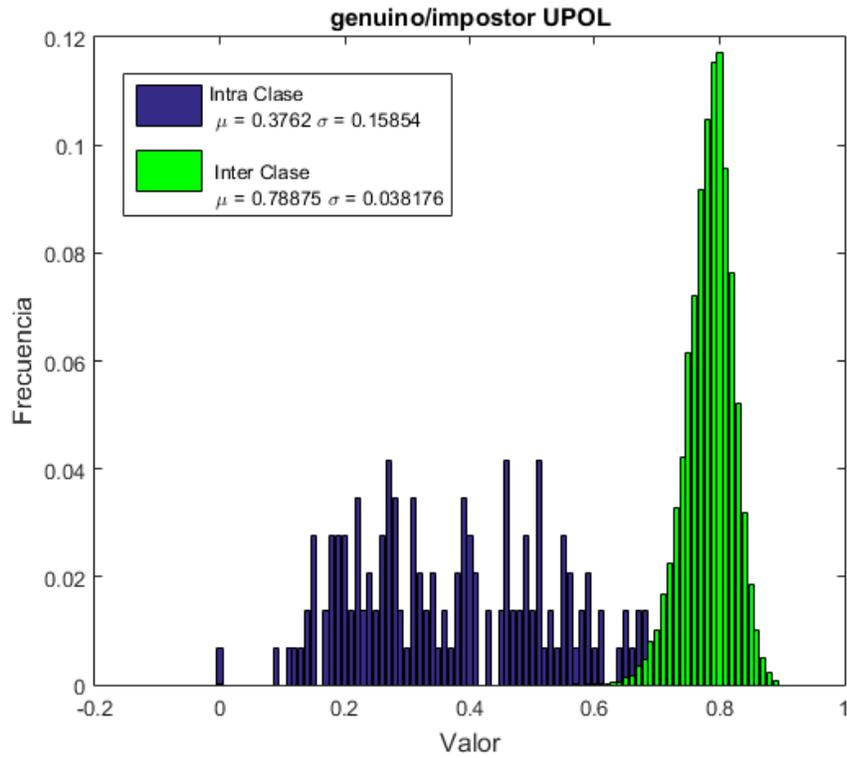


Figura 42. Distribuciones genuinas e impostoras base de datos UPOL.

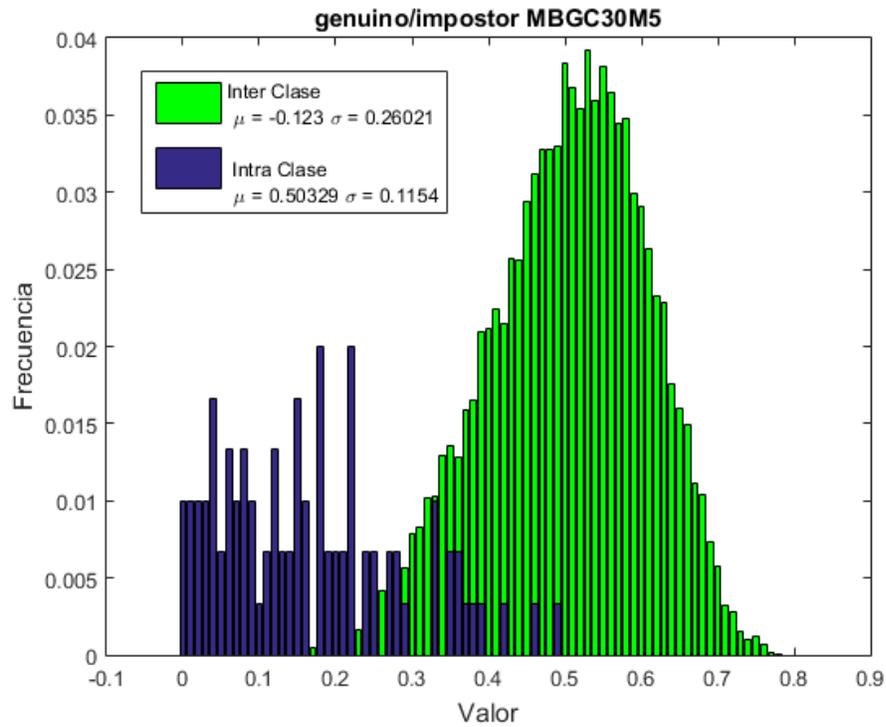


Figura 43. Distribuciones genuinas e impostoras en la base de datos MBGC de 30 personas.

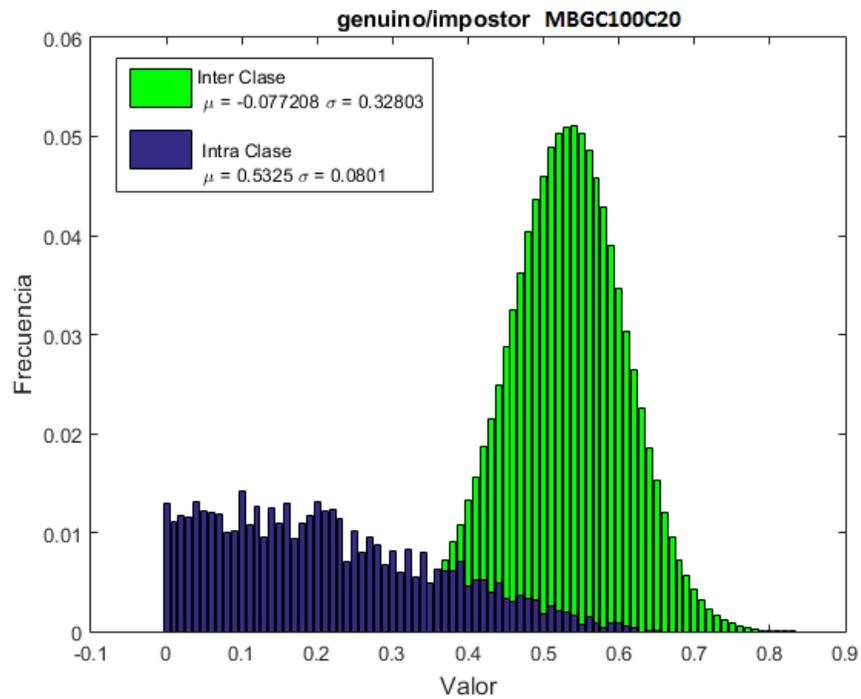


Figura 44. Distribuciones genuinas e impostoras en base de datos MBGC de 100 personas.

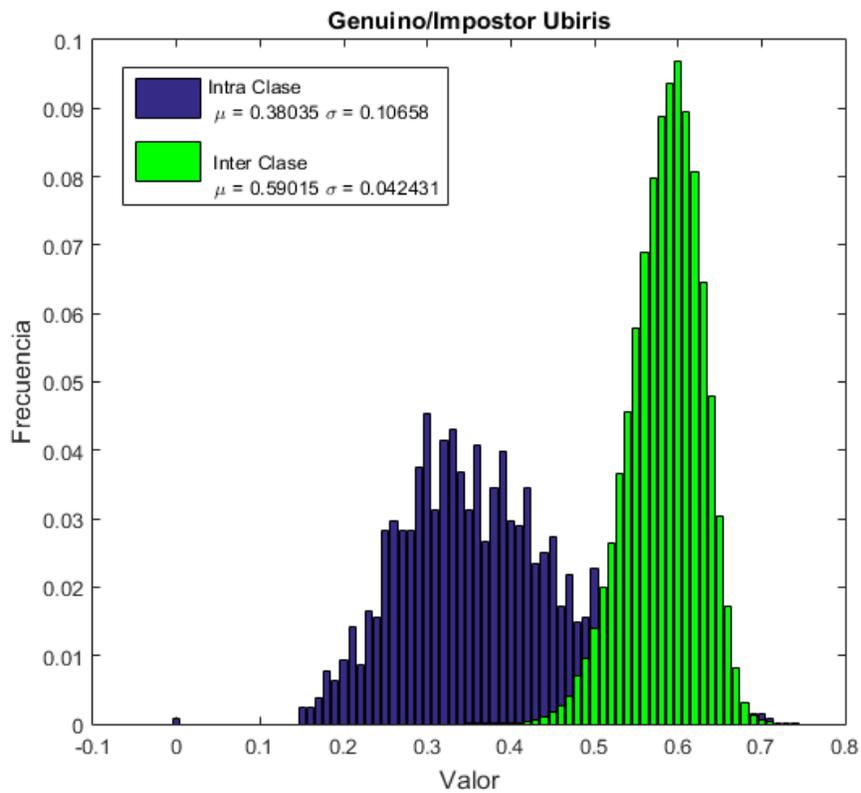


Figura 45. Distribuciones genuinas e impostoras en base de datos Ubris.

Referencias

- [1] S. Z. Li and A. K. Jain, Eds., *Encyclopedia of biometrics*. New York: Springer, 2009.
- [2] A. K. Jain, A. Ross, and S. Prabhakar, "An introduction to biometric recognition," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 14, no. 1, pp. 4–20, Jan. 2004.
- [3] K. Revett, *Behavioral Biometrics: A Remote Access Approach*. John Wiley & Sons, 2008.
- [4] J. Daugman, "Probing the Uniqueness and Randomness of IrisCodes: Results From 200 Billion Iris Pair Comparisons," *Proc. IEEE*, vol. 94, no. 11, pp. 1927–1935, Nov. 2006.
- [5] J. Daugman, "How iris recognition works," in *2002 International Conference on Image Processing. 2002. Proceedings*, 2002, vol. 1, p. I-33-I-36.
- [6] J. Daugman and C. Downing, "Epigenetic randomness, complexity and singularity of human iris patterns.," *Proc. R. Soc. B Biol. Sci.*, vol. 268, no. 1477, pp. 1737–1740, Aug. 2001.
- [7] C. Rathgeb, A. Uhl, and P. Wild, *Iris biometrics: from segmentation to template security*. New York: Springer, 2013.
- [8] K. W. Bowyer, K. Hollingsworth, and P. J. Flynn, "Image Understanding for Iris Biometrics: A Survey," *Comput Vis Image Underst.*, vol. 110, no. 2, pp. 281–307, May 2008.
- [9] A. Nigam and P. Gupta, "Multimodal Personal Authentication Using Iris and Knuckleprint," in *Intelligent Computing Theory*, D.-S. Huang, V. Bevilacqua, and P. Premaratne, Eds. Springer International Publishing, 2014, pp. 819–825.
- [10] "IrisGuard." [Online]. Available: <http://www.irisguard.com/index.php/about>. [Accessed: 04-Nov-2016].
- [11] "Samsung Galaxy Note7 (USA) - Full phone specifications." [Online]. Available: [http://www.gsmarena.com/samsung_galaxy_note7_\(usa\)-8242.php](http://www.gsmarena.com/samsung_galaxy_note7_(usa)-8242.php). [Accessed: 04-Nov-2016].
- [12] "Global Iris Recognition Market 2015-2019 | Technavio - Discover Market Opportunities." [Online]. Available: http://www.technavio.com/report/global-iris-recognition-market-2015-2019?utm_source=T2&utm_medium=BW&utm_campaign=Media. [Accessed: 04-Nov-2016].
- [13] J. G. Daugman, "High confidence visual recognition of persons by a test of statistical independence," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 15, no. 11, pp. 1148–1161, Nov. 1993.
- [14] "Biometric personal identification system based on iris analysis."
- [15] "Iridian Technologies -," *Iridian Technologies*. [Online]. Available: <http://www.iri-diantech.com>. [Accessed: 05-Dec-2015].
- [16] "LG Iris," *Aditech*. [Online]. Available: <http://aditech.co.uk/lg-iris/>. [Accessed: 04-Nov-2016].
- [17] I. Id, "iCAM4000 series," *Iris ID*. [Online]. Available: <http://www.irisid.com/productsolutions/hardwareproducts/icam4000series/>. [Accessed: 04-Nov-2016].
- [18] A. N. Al-Raisi and A. M. Al-Khouri, "Iris recognition and the challenge of homeland and border control security in UAE," *Telemat. Inform.*, vol. 25, no. 2, pp. 117–132, May 2008.
- [19] J. Daugman, "Iris recognition border-crossing system in the UAE," *Int. Airt. Rev.*, vol. 8, no. 2, 2004.
- [20] J. Daugman, "Iris recognition at airports and border-crossings," in *Encyclopedia of Biometrics*, New York: Springer, 2009.
- [21] M. J. Burge and K. Bowyer, *Handbook of Iris Recognition*. Springer Science & Business Media, 2013.
- [22] L. Ma, T. Tan, Y. Wang, and D. Zhang, "Personal identification based on iris texture analysis," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 25, no. 12, pp. 1519–1533, Dec. 2003.
- [23] J. R. Matey and L. R. Kennell, "Iris Recognition – Beyond One Meter," in *Handbook of Remote Biometrics*, M. Tistarelli, D. S. Z. Li, and D. R. Chellappa, Eds. Springer London, 2009, pp. 23–59.
- [24] R. P. Wildes, "Iris recognition: an emerging biometric technology," *Proc. IEEE*, vol. 85, no. 9, pp. 1348–1363, Sep. 1997.
- [25] W. W. Boles and B. Boashash, "A human identification technique using images of the iris and wavelet transform," *IEEE Trans. Signal Process.*, vol. 46, no. 4, pp. 1185–1188, Apr. 1998.
- [26] C. Sanchez-Avila, R. Sanchez-Reillo, and D. de Martin-Roche, "Iris-based biometric recognition using dyadic wavelet transform," *IEEE Aerosp. Electron. Syst. Mag.*, vol. 17, no. 10, pp. 3–6, Oct. 2002.
- [27] L. Ma, T. Tan, Y. Wang, and D. Zhang, "Efficient iris recognition by characterizing key local variations," *IEEE Trans. Image Process.*, vol. 13, no. 6, pp. 739–750, Jun. 2004.
- [28] Z. Sun, Y. Wang, T. Tan, and J. Cui, "Improving iris recognition accuracy via cascaded classifiers," *IEEE Trans. Syst. Man Cybern.*, vol. 35, 2005.
- [29] D. M. Monro and Z. Zhang, "An effective human iris code with low complexity," in *IEEE International Conference on Image Processing 2005*, 2005, vol. 3, p. III-277-80.
- [30] Z. Sun, T. Tan, and X. Qiu, "Graph Matching Iris Image Blocks with Local Binary Pattern," in *Advances in Biometrics*, D. Zhang and A. K. Jain, Eds. Springer Berlin Heidelberg, 2005, pp. 366–372.
- [31] A. Zaim, A. Sawalha, M. Quweider, J. Iglesias, and R. Tang, "A New Method for Iris Recognition using Gray-Level Cooccurrence Matrix," in *2006 IEEE International Conference on Electro/information Technology*, 2006, pp. 350–353.
- [32] R. Zhu, J. Yang, and R. Wu, "Iris Recognition Based on Local Feature Point Matching," in *International Symposium on Communications and Information Technologies, 2006. ISCIT '06*, 2006, pp. 451–454.
- [33] D. M. Monro, S. Rakshit, and D. Zhang, "DCT-Based Iris Recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 29, no. 4, pp. 586–595, Apr. 2007.

- [34] J.-G. Ko, Y.-H. Gil, J.-H. Yoo, and K.-I. Chung, "A Novel and Efficient Feature Extraction Method for Iris Recognition," *ETRI J.*, vol. 29, no. 3, pp. 399–401, Jun. 2007.
- [35] K. Miyazawa, K. Ito, T. Aoki, K. Kobayashi, and H. Nakajima, "An Effective Approach for Iris Recognition Using Phase-Based Image Matching," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 30, no. 10, pp. 1741–1756, Oct. 2008.
- [36] C. Lu and Z. Lu, "Local feature extraction for iris recognition with automatic scale selection," *Image Vis. Comput.*, vol. 26, no. 7, pp. 935–940, Jul. 2008.
- [37] W.-S. Chen, R.-H. Huang, and L. Hsieh, "Iris Recognition Using 3D Co-occurrence Matrix," in *Advances in Biometrics*, M. Tistarelli and M. S. Nixon, Eds. Springer Berlin Heidelberg, 2009, pp. 1122–1131.
- [38] Z. Sun and T. Tan, "Ordinal Measures for Iris Recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 31, no. 12, pp. 2211–2226, Dec. 2009.
- [39] F. Alonso-Fernandez, P. Tome-Gonzalez, V. Ruiz-Albacete, and J. Ortega-Garcia, "Iris recognition based on SIFT features," in *2009 International Conference on Biometrics, Identity and Security (BIDS)*, 2009, pp. 1–8.
- [40] C. Rathgeb and A. Uhl, "Secure Iris Recognition Based on Local Intensity Variations," in *Image Analysis and Recognition*, A. Campilho and M. Kamel, Eds. Springer Berlin Heidelberg, 2010, pp. 266–275.
- [41] M. Y. Shams, M. Z. Rashad, O. Nomir, and R. M. El-Awady, "Iris Recognition Based on LBP and Combined LVQ Classifier," *Int. J. Comput. Sci. Inf. Technol.*, vol. 3, no. 5, pp. 67–78, Oct. 2011.
- [42] Masek, L and Kovesi, P, "MATLAB Source Code for a Biometric Identification System Based on Iris Patterns." [Online]. Available: <http://www.peterkovesi.com/studentprojects/libor/>. [Accessed: 27-Nov-2015].
- [43] G. Yang, S. Pang, Y. Yin, Y. Li, and X. Li, "SIFT based iris recognition with normalization and enhancement," *Int. J. Mach. Learn. Cybern.*, vol. 4, no. 4, pp. 401–407, Jun. 2012.
- [44] M. De Marsico, M. Nappi, and D. Riccio, "Noisy Iris Recognition Integrated Scheme," *Pattern Recognit. Lett.*, vol. 33, no. 8, pp. 1006–1011, Jun. 2012.
- [45] "ISO/IEC 19794-6:2005 - Information technology -- Biometric data interchange formats -- Part 6: Iris image data." [Online]. Available: http://www.iso.org/iso/catalogue_detail.htm?csnumber=38750. [Accessed: 21-Oct-2015].
- [46] M. De Marsico, M. Nappi, and D. Riccio, "Noisy Iris Recognition Integrated Scheme," *Pattern Recognit. Lett.*, vol. 33, no. 8, pp. 1006–1011, Jun. 2012.
- [47] C.-W. Tan and A. Kumar, "Efficient and Accurate At-a-Distance Iris Recognition Using Geometric Key-Based Iris Encoding," *IEEE Trans. Inf. Forensics Secur.*, vol. 9, no. 9, pp. 1518–1526, Sep. 2014.
- [48] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, Jul. 2002.
- [49] T. Ojala, M. Pietikainen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern Recognit.*, vol. 29, no. 1, pp. 51–59, Jan. 1996.
- [50] "Texture Matching using Local Binary Patterns (LBP), OpenCV, scikit-learn and Python." [Online]. Available: <http://hanzratech.in/2015/05/30/local-binary-patterns.html>. [Accessed: 28-Nov-2016].
- [51] H. R. E. Doost and M. C. Amirani, "Texture Classification with Local Binary Pattern Based on Continues Wavelet Transformation," *Int. J. Adv. Res. Electr. Electron. Instrum. Energy*, Oct. 2013.
- [52] Z. Guo, D. Zhang, and D. Zhang, "A Completed Modeling of Local Binary Pattern Operator for Texture Classification," *IEEE Trans. Image Process.*, vol. 19, no. 6, pp. 1657–1663, Jun. 2010.
- [53] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Trans. Syst. Man Cybern.*, vol. SMC-3, no. 6, pp. 610–621, Nov. 1973.
- [54] "Create gray-level co-occurrence matrix from image - MATLAB graycomatrix." [Online]. Available: <https://www.mathworks.com/help/images/ref/graycomatrix.html>. [Accessed: 28-Nov-2016].
- [55] "Properties of gray-level co-occurrence matrix - MATLAB graycoprops." [Online]. Available: <https://www.mathworks.com/help/images/ref/graycoprops.html>. [Accessed: 29-Nov-2016].
- [56] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes: Active contour models," *Int. J. Comput. Vis.*, vol. 1, no. 4, pp. 321–331, Jan. 1988.
- [57] D. Mumford and J. Shah, "Optimal approximations by piecewise smooth functions and associated variational problems," *Commun. Pure Appl. Math.*, vol. 42, no. 5, pp. 577–685, Jul. 1989.
- [58] W. Zhou and Y. Xie, "Interactive Medical Image Segmentation Using Snake and Multiscale Curve Editing," *Comput. Math. Methods Med.*, vol. 2013, p. e325903, Dec. 2013.
- [59] S. Y. Yeo, X. Xie, I. Sazonov, and P. Nithiarasu, "Segmentation of biomedical images using active contour model with robust image feature and shape prior," *Int. J. Numer. Methods Biomed. Eng.*, vol. 30, no. 2, pp. 232–248, Feb. 2014.
- [60] Z. Fan, J. Zhou, D. Gao, and L. Zhiheng, "Contour extraction and tracking of moving vehicles for traffic monitoring," in *The IEEE 5th International Conference on Intelligent Transportation Systems, 2002. Proceedings*, 2002, pp. 84–87.
- [61] C. L. D. Ye and Y. Zheng, "A Survey on Image Segmentation Using Geometric Active Contour Model," in *Proceedings of the 2012 Second International Conference on Electric Information and Control Engineering - Volume 01*, Washington, DC, USA, 2012, pp. 233–236.
- [62] M. M. Abdelsamea, G. Gnecco, and M. M. Gaber, "A Survey of SOM-Based Active Contour Models for Image Segmentation," in *SpringerLink*, Springer International Publishing, pp. 293–302.
- [63] C. Sagiv, N. A. Sochen, and Y. Y. Zeevi, "Integrated active contours for texture segmentation," *IEEE Trans. Image Process. Publ. IEEE Signal Process. Soc.*, vol. 15, no. 6, pp. 1633–1646, Jun. 2006.

- [64] A. Tatu and S. Bansal, "A Novel Active Contour Model for Texture Segmentation," in *SpringerLink*, Springer International Publishing, 2015, pp. 223–236.
- [65] P. Lv, Q. Zhao, and D. Gu, "Segmenting similar shapes via weighted group-similarity active contours," in *2015 IEEE International Conference on Image Processing (ICIP)*, 2015, pp. 4032–4036.
- [66] J. Li and A. O. Hero, "A spectral method for solving elliptic equations for surface reconstruction and 3D active contours," in *2001 International Conference on Image Processing, 2001. Proceedings*, 2001, vol. 3, pp. 1067–1070 vol.3.
- [67] X. Bresson, S. Esedoglu, P. Vandergheynst, J.-P. Thiran, and S. Osher, "Fast Global Minimization of the Active Contour/Snake Model," *J Math Imaging Vis*, vol. 28, no. 2, pp. 151–167, Jun. 2007.
- [68] A. F. Caregnato and V. C. Costa, "La segmentación de imágenes: el método de los contornos activos geométricos," *Encuentros Multidiscipl.*, vol. 8, no. 23, pp. 14–26, 2006.
- [69] A. K. Mishra, P. Fieguth, and D. A. Clausi, "Robust snake convergence based on dynamic programming," in *2008 15th IEEE International Conference on Image Processing*, 2008, pp. 1092–1095.
- [70] N. M. Khan and K. Raahemifar, "A novel Accelerated Greedy Snake Algorithm for active contours," in *2011 24th Canadian Conference on Electrical and Computer Engineering (CCECE)*, 2011, pp. 000186–000190.
- [71] V. Caselles, F. Catté, T. Coll, and F. Dibos, "A geometric model for active contours in image processing," *Numer. Math.*, vol. 66, no. 1, pp. 1–31, Dec. 1993.
- [72] V. Caselles, R. Kimmel, and G. Sapiro, "Geodesic Active Contours," *Int. J. Comput. Vis.*, vol. 22, no. 1, pp. 61–79, Feb. 1997.
- [73] S. Kichenassamy, A. Kumar, P. Olver, A. Tannenbaum, and A. Y. Jr, "Conformal curvature flows: From phase transitions to active vision," *Arch. Ration. Mech. Anal.*, vol. 134, no. 3, pp. 275–301, Sep. 1996.
- [74] G. Sapiro, *Geometric partial differential equations and image analysis*, 1. paperback ed. Cambridge: Cambridge Univ. Press, 2006.
- [75] V. Caselles, F. Catté, T. Coll, and F. Dibos, "A geometric model for active contours in image processing," *Numer. Math.*, vol. 66, no. 1, pp. 1–31, Dec. 1993.
- [76] L. I. Rudin, S. Osher, and E. Fatemi, "Nonlinear total variation based noise removal algorithms," *Phys. Nonlinear Phenom.*, vol. 60, no. 1–4, pp. 259–268, Nov. 1992.
- [77] W. Al-Faqheri, "A Real-Time Malaysian Automatic License Plate Recognition (M-ALPR) using Hybrid Fuzzy," *IJCSNS Int. J. Comput. Sci. Netw. Secur.*, vol. 9, pp. 333–340, Feb. 2009.
- [78] M. Vatsa, R. Singh, P. Mitra, and A. Noore, "Signature Verification Using Static and Dynamic Features," in *SpringerLink*, Springer Berlin Heidelberg, pp. 350–355.
- [79] A. Fernández, O. Ghita, E. González, F. Bianconi, and P. F. Whelan, "Evaluation of robustness against rotation of LBP, CCR and ILBP features in granite texture classification," *Mach. Vis. Appl.*, vol. 22, no. 6, pp. 913–926, Feb. 2010.
- [80] J. Heikkila, V. Ojansivu, and E. Rahtu, "Improved Blur Insensitivity for Decorrelated Local Phase Quantization," in *2010 20th International Conference on Pattern Recognition (ICPR)*, 2010, pp. 818–821.
- [81] A. Mucherino, P. J. Papajorgji, and P. M. Pardalos, "k-Nearest Neighbor Classification," in *Data Mining in Agriculture*, Springer New York, 2009, pp. 83–106.
- [82] P. Refaeilzadeh, L. Tang, and H. Liu, "Cross-Validation," in *Encyclopedia of Database Systems*, L. LIU and M. T. ÖzSU, Eds. Springer US, 2009, pp. 532–538.
- [83] P. Brodatz, *Textures: a photographic album for artists and designers*, by Phil Brodatz. New York: Dover publications, 1966.
- [84] "Trygve Randen. Brodatz textures at Trygve Randen's website." [Online]. Available: <http://www.ux.uio.no/~tranden/>. [Accessed: 28-Mar-2016].
- [85] "Mondial Marmi: a granite image database for colour and texture analysis." [Online]. Available: http://dismac.dii.unipg.it/mm/ver_1_1/. [Accessed: 28-Mar-2016].
- [86] M. Polak, H. Zhang, and M. Pi, "An evaluation metric for image segmentation of multiple objects," *Image Vis. Comput.*, vol. 27, no. 8, pp. 1223–1227, Jul. 2009.
- [87] R. Shi, K. N. Ngan, and S. Li, "Jaccard index compensation for object segmentation evaluation," in *2014 IEEE International Conference on Image Processing (ICIP)*, 2014, pp. 4457–4461.
- [88] "Michal Dobeš and Libor Machala, UPOL Iris Database." [Online]. Available: <http://www.inf.upol.cz/iris/>. [Accessed: 02-Nov-2016].
- [89] H. Proença and L. A. Alexandre, "UBIRIS: A Noisy Iris Image Database," in *Image Analysis and Processing – ICIAP 2005*, F. Roli and S. Vitulano, Eds. Springer Berlin Heidelberg, 2005, pp. 970–977.
- [90] P. J. Phillips *et al.*, "Overview of the Multiple Biometrics Grand Challenge," in *Advances in Biometrics*, M. Tistarelli and M. S. Nixon, Eds. Springer Berlin Heidelberg, 2009, pp. 705–714.
- [91] R. Parashar and S. Joshi, "Comparative Study of Iris Databases and UBIRIS Database for Iris Recognition Methods for Non-Cooperative Environment," presented at the International Journal of Engineering Research and Technology, 2012, vol. Vol.1-Issue 5 (July-2012).
- [92] S. Ribaric and I. Fratric, "Experimental Evaluation of Matching-Score Normalization Techniques on Different Multimodal Biometric Systems," in *MELECON 2006 - 2006 IEEE Mediterranean Electrotechnical Conference*, 2006, pp. 498–501.

- [93] L. Didaci, G. L. Marcialis, and F. Roli, "Modelling FRR of Biometric Verification Systems Using the Template Co-update Algorithm," in *SpringerLink*, Springer Berlin Heidelberg, pp. 765–774.
- [94] N. Japkowicz and M. Shah, *Evaluating Learning Algorithms: A Classification Perspective*. Cambridge University Press, 2011.
- [95] S. Furui, "Speech and Speaker Recognition Evaluation," in *Evaluation of Text and Speech Systems*, P. L. Dybkjær, H. Hensen, and P. W. Minker, Eds. Springer Netherlands, 2007, pp. 1–27.
- [96] J. P. Egan, *Signal Detection Theory and ROC-analysis*. Academic Press, 1975.
- [97] C. E. Metz, "Basic principles of ROC analysis," *Semin. Nucl. Med.*, vol. 8, no. 4, pp. 283–298, Oct. 1978.
- [98] K. A. Spackman, "Signal Detection Theory: Valuable Tools for Evaluating Inductive Learning," in *Proceedings of the Sixth International Workshop on Machine Learning*, San Francisco, CA, USA, 1989, pp. 160–163.
- [99] J. Huang and C. X. Ling, "Using AUC and accuracy in evaluating learning algorithms," *IEEE Trans. Knowl. Data Eng.*, vol. 17, no. 3, pp. 299–310, Mar. 2005.
- [100] J. Davis and M. Goadrich, "The Relationship Between Precision-Recall and ROC Curves," in *Proceedings of the 23rd International Conference on Machine Learning*, New York, NY, USA, 2006, pp. 233–240.
- [101] R. Kohavi and F. Provost, "Glossary of terms," *Mach. Learn.*, vol. 30, no. 2–3, pp. 271–274, 1998.
- [102] D. H. Wang and D. H. Zheng, "Negative Predictive Value," in *Encyclopedia of Systems Biology*, W. Dubitzky, O. Wolkenhauer, K.-H. Cho, and H. Yokota, Eds. Springer New York, 2013, pp. 1505–1505.
- [103] C. Lobrano, R. Tronci, G. Giacinto, and F. Roli, "A Score Decidability Index for Dynamic Score Combination," in *ResearchGate*, 2010, pp. 69–72.
- [104] S. M. Pizer *et al.*, "Adaptive Histogram Equalization and Its Variations," *Comput Vis. Graph Image Process*, vol. 39, no. 3, pp. 355–368, Sep. 1987.
- [105] M. S. García-Vázquez, E. Garea-Llano, J. M. Colores-Vargas, L. M. Zamudio-Fuentes, and A. A. Ramírez-Acosta, "A Comparative Study of Robust Segmentation Algorithms for Iris Verification System of High Reliability," in *Pattern Recognition*, J. A. Carrasco-Ochoa, J. F. Martí-nez-Trinidad, J. H. Sossa-Azuela, J. A. O. López, and F. Famili, Eds. Springer International Publishing, 2015, pp. 156–165.
- [106] R. Hentati, M. Abid, and B. Dorizzi, "Software implementation of the OSIRIS iris recognition algorithm in FPGA," in *2011 International Conference on Microelectronics (ICM)*, 2011, pp. 1–5.
- [107] D. G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," *Int J Comput Vis.*, vol. 60, no. 2, pp. 91–110, Nov. 2004.
- [108] D. G. Lowe, "Object recognition from local scale-invariant features," in *The Proceedings of the Seventh IEEE International Conference on Computer Vision, 1999*, 1999, vol. 2, pp. 1150–1157 vol.2.
- [109] K. Mikolajczyk and C. Schmid, "A performance evaluation of local descriptors," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 27, no. 10, pp. 1615–1630, Oct. 2005.