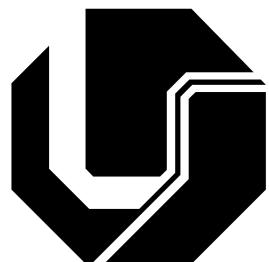


**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**



**Reconhecimento Biométrico Considerando a
Deformação não Linear da Íris Humana**

Cláriton Rodrigues Bernadelli

Uberlândia, MG

2016

Reconhecimento Biométrico Considerando a Deformação não Linear da Íris Humana

Cláriton Rodrigues Bernadelli

Documento apresentado ao Programa de Pós Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como requisito parcial para obtenção do título de Doutor em Ciências - Área de concentração: Processamento Digital de Sinais.

Prof. Dr. Antônio C. P. Veiga
Orientador

Prof. Dr. Darizon Alves de Andrade
Coordenador do curso de Pós-Graduação

Uberlândia, MG

2016

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

B517r Bernadelli, Cláriton Rodrigues, 1979-
2016 Reconhecimento biométrico considerando a deformação não linear
da íris humana / Cláriton Rodrigues Bernadelli. - 2016.
100 f. : il.

Orientador: Antônio Cláudio Paschoarelli Veiga.
Tese (doutorado) - Universidade Federal de Uberlândia, Programa
de Pós-Graduação em Engenharia Elétrica.
Inclui bibliografia.

1. Engenharia elétrica - Teses. 2. Biometria - Teses. 3. Iris (Olhos) -
Teses. I. Veiga, Antônio Cláudio Paschoarelli, 1963- II. Universidade
Federal de Uberlândia. Programa de Pós-Graduação em Engenharia
Elétrica. III. Título.

CDU: 621.3

Reconhecimento Biométrico Considerando a Deformação não Linear da Íris Humana

Cláriton Rodrigues Bernadelli

Documento apresentado ao Programa de Pós Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como requisito parcial para obtenção do título de Doutor em Ciências - Área de concentração: Processamento Digital de Sinais.

Aprovada em 27 de Junho de 2016.

Banca examinadora:

Antônio. C. P. Veiga, Dr. - Orientador (UFU)

Marcelo Ponciano da Silva, Dr. (IFTM)

Luciano Xavier Medeiros, Dr. (UFTM)

Milena Bueno Pereira, Dra. (UFU)

Gilberto Arantes Carrijo, Dr. (UFU)

*Dedico este trabalho ao meu grande amor, amiga e esposa Adriana Barcelos,
pessoa mais encantadora e cativante que conheci.*

Agradecimentos

A Deus, por fazer tudo possível.

À minha amada esposa Adriana Barcelos, pelo amor, carinho, amizade e companheirismo de sempre.

Aos meus amados pais Henrique José Bernadelli e Eunice Rodrigues, pelo amor e apoio incondicional.

Ao meu orientador Prof. Dr. Paschoarelli, pela confiança depositada em mim, pelo apoio e cuidado que sempre demonstrou.

Ao meu ex-aluno e agora colega de profissão Paulo Ricardo, pela imprescindível ajuda.

Aos meus alunos, pelo aprendizado e inspiração.

À CAPES e à FAPEMIG pelo suporte financeiro a este trabalho.

Resumo

Bernadelli, C. R. & Veiga, A. C. P. Reconhecimento Biométrico Considerando a Deformação não Linear da Íris Humana.

Processamento Digital de Imagens - FEELT-UFU, Uberlândia, 2016, 100p.

Os sistemas biométricos que utilizam a informação contida na textura da íris têm recebido grande atenção nos últimos anos. A grande variação em textura da íris permite o desenvolvimento de sistemas de reconhecimento e de identificação com taxas de erro quase nulas. Entretanto, de forma geral, as pesquisas nesta área ignoram os problemas associados aos movimentos de contração e dilatação da íris que geram diferenças significativas entre as imagens inscritas em uma base de dados e a imagem de teste.

Este trabalho, além de desenvolver um sistema de reconhecimento de íris tradicional, composto pelas etapas de detecção, segmentação, normalização, codificação e comparação, determina de forma quantitativa o efeito dos movimentos da íris na precisão do sistema de reconhecimento. Além disso, este trabalho propõe um novo método para diminuir a influência da dinâmica da íris, verificado pela decidibilidade e pela Taxa de Erro Igual (EER), obtidas na comparação entre códigos de íris em estados de dilatação bem diferentes.

O novo método utiliza a técnica Dynamic Time Warping para corrigir e comparar os vetores de gradientes extraídos da textura da íris. Dessa forma, as características mais discriminantes da imagem de teste e da imagem da galeria são alinhadas e comparadas, considerando a deformação não linear do tecido da íris.

Os resultados experimentais, utilizando imagens dinâmicas, indicam que a performance do sistema piora quando a comparação é feita com imagens em estados de contração diferentes. Para a comparação direta entre íris bem contraída com íris bem dilatada o método proposto melhora a decidibilidade de 3,50 para 4,39 e a EER de 9,69% para 3,36%.

Palavras-chave

Biometria, CASIA-IRIS-Lamp, decidibilidade, Dynamic Time Warping, EER, Histograma de Gradientes Orientados.

Abstract

Bernadelli, C. R. & Veiga, A. C. P. Biometric Recognition Considering Nonlinear Deformation of Human Iris.

Digital Image Processing - FEELT-UFG, Uberlândia, 2016, 100p.

The biometric systems that use the information on iris texture has received great attention in recent years. The extraordinary variation in iris texture allows the creation of recognition and identification systems with almost zero error rates. However, in general, researches ignore the problems associated with contraction and dilation iris movements that can result in significant differences between the enrollment images and the probe image.

This work, in addition to developing a traditional iris recognition system, comprising the steps of detection, segmentation, normalization, encoding and comparison, determines quantitatively the iris motion effect in recognition system accuracy. In addition, this paper proposes a new method to reduce the influence of dynamic iris, verified by decidability and the Equal Error Rate (EER), obtained in the comparison between iris codes in very different expansion states.

The new method uses Dynamic Time Warping technique to correct and compare the gradient vectors extracted from iris texture. Thus, the most discriminant features of the test image and enrollment image are aligned and compared, considering the non-linear distortion of the iris tissue.

Experimental results using dynamic images indicate that system performance gets worse with comparison on images in different states contraction. For direct comparison with contracted and dilated iris the proposed method improves the decidability of 3.50 to 4.39 and EER of 9.69% to 3.36%.

Keywords

Biometrics, CASIA-IRIS-Lamp, Decidability, EER, Dynamic Time Warping, Histogram of Oriented Gradients.

Sumário

Sumário	viii
Lista de Figuras	xi
Lista de Tabelas	xiii
Lista de Abreviações	xiv
1 Introdução	1
1.1 A Íris Humana	1
1.2 Reconhecimento Biométrico da Íris	2
1.3 Motivação: Deformação da Íris e o Reconhecimento Biométrico	3
1.4 Objetivos	4
1.4.1 Objetivos Específicos deste Trabalho	5
1.5 Estrutura do Documento	5
2 Segmentação	8
2.1 Introdução	8
2.2 Transformada de Hough	9
2.3 Operador Integro-diferencial	10
2.4 Estado da Arte	11
2.5 Implementação	12
2.6 Resultados	13
2.7 Considerações Finais do Capítulo	15

3	Normalização	17
3.1	Introdução	17
3.2	O Modelo Homogeneous Rubber Sheet	18
3.3	Estado da Arte	19
3.4	Implementação	20
3.5	Resultados	21
3.6	Considerações Finais do Capítulo	22
4	Codificação e Comparação	24
4.1	Introdução	24
4.2	Filtros de Gabor	25
4.3	Distância de Hamming	26
4.4	Estado da Arte	27
4.4.1	Análise e representação da textura da íris	27
4.4.2	Análise e representação da correspondência entre códigos de íris	31
4.5	Implementação	33
4.6	Resultados	35
5	Desempenho do Sistema	38
5.1	Introdução	38
5.2	Resultados Experimentais	40
5.2.1	Experimento 1	42
5.2.2	Experimento 2	44
5.2.3	Experimento 3	47
5.3	Discussão	50
5.4	Conclusão	52
6	Método Proposto para a Extração das Características Permanentes da Íris	54
6.1	Introdução	54
6.2	Definindo o Problema	55
6.3	Método Proposto	57
6.3.1	Histogramas de Gradientes Orientados - HoG	58
6.3.2	Dynamic Time Warping - DTW	60
6.4	Implementação	62
6.5	Resultados Experimentais	63
6.6	Discussão	68
6.7	Considerações Finais	70

7 Conclusões, Contribuições e Sugestões de Trabalhos Futuros	71
7.1 Resumo das Implementações	71
7.2 Conclusões e Contribuições	75
7.3 Sugestões de Trabalhos Futuros	75
7.4 Principais Publicações	76
Referências	78

Lista de Figuras

1.1	<i>Elementos vistos em uma imagem típica do olho humano.</i>	1
2.1	<i>Detecção de bordas pelo método de Canny.</i>	9
2.2	<i>Transformada de Hough para círculos.</i>	10
2.3	<i>Processo de exclusão das pálpebras.</i>	13
2.4	<i>Imagens da íris segmentada.</i>	14
2.5	<i>Falhas no processo de segmentação.</i>	15
3.1	<i>Representação retangular da região da íris proposta por John Daugman.</i>	18
3.2	<i>Normalização com resolução radial igual a 10 pixels e resolução angular igual a 40 pixels.</i>	20
3.3	<i>Resultado da aplicação do algoritmo de normalização em uma imagem.</i>	22
3.4	<i>Normalização das imagens de duas íris em instantes diferentes.</i>	22
4.1	<i>Níveis de quantização de acordo com o quadrante do plano complexo.</i>	34
4.2	<i>Cálculo da DH para templates deslocados.</i>	35
4.3	<i>Template binária e a máscara de ruídos gerados a partir de uma imagem normalizada da íris.</i>	36
4.4	<i>Distribuição das distâncias de Hamming com deslocamento de bits para as imagens utilizadas. Melhor distribuição encontrada com até 8 deslocamentos.</i>	37
4.5	<i>Distribuição das distâncias de Hamming sem deslocamento de bits para as imagens utilizadas.</i>	37
5.1	<i>Representação das distribuições intraclasse e interclasse - Ambiente de decisão.</i>	38
5.2	<i>Distribuição das distâncias de Hamming para os conjuntos de imagens CASIA-IrisV1 e CASIA-IRIS-Lamp.</i>	39
5.3	<i>Cumulative Match Characteristic para CASIA-IrisV1 e CASIA-IRIS-Lamp.</i>	43
5.4	<i>Receiver Operating Characteristic para CASIA-IrisV1 e CASIA-IRIS-Lamp.</i>	44

5.5	<i>Distribuição da taxa de dilatação. Raio da pupila dividido pelo raio da íris.</i>	45
5.6	<i>Distribuição das distâncias de Hamming de acordo com a taxa de dilatação.</i>	46
5.7	<i>ROC para os três intervalos de taxa de dilatação.</i>	47
5.8	<i>Distribuição das distâncias de Hamming entre os Subconjuntos (1 e 2), (1 e 3) e (2 e 3).</i>	48
5.9	<i>ROC para a comparação entre os subconjuntos.</i>	50
6.1	<i>Mapeamento de 54 números complexos que representam a saída do filtro de extração de características da mesma região da íris.</i>	56
6.2	<i>Representação gráfica do processo de extração de características HoG.</i>	60
6.3	<i>Representação gráfica da construção do caminho deformado da DTW.</i>	62
6.4	<i>Diagrama de blocos do sistema de alinhamento das características dinâmicas.</i>	62
6.5	<i>Indicação da posição das células menos similares entre as imagens da galeria e da imagem de teste.</i>	63
6.6	<i>Distribuição das distâncias de Hamming de acordo com a taxa de dilatação utilizando máscara dinâmica.</i>	64
6.7	<i>ROC para os três intervalos de taxa de dilatação utilizando máscara dinâmica.</i>	65
6.8	<i>Distribuição das distâncias de Hamming entre os Subconjuntos (1), (2) e (3) utilizando máscara dinâmica.</i>	67
6.9	<i>ROC para a comparação entre os subconjuntos utilizando máscara dinâmica.</i>	68

Lista de Tabelas

4.1	<i>Imagens utilizadas para realizar testes com sistema.</i>	36
5.1	<i>Matriz de confusão utilizada para mostrar o desempenho do sistema.</i>	41
5.2	<i>Matriz de confusão do melhor resultado - Threshold = 0, 40.</i>	43
5.3	<i>Matriz de confusão do melhor resultado para cada subconjunto.</i>	47
5.4	<i>Experimento 3. Verificação entre imagens de subconjuntos diferentes.</i>	47
5.5	<i>Matriz de confusão do melhor resultado para comparação entre subconjuntos.</i>	49
6.1	<i>Matriz de confusão do melhor resultado para cada subconjunto.</i>	66
6.2	<i>Matriz de confusão do melhor resultado para comparação entre subconjuntos.</i>	69
7.1	<i>Resultados dos três experimentos realizados - Resumo.</i>	74
7.2	<i>Resultados dos experimentos realizados utilizando máscara dinâmica - Resumo.</i>	74

Lista de Abreviações

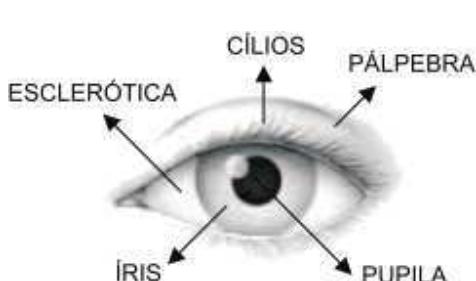
CHT	Circle Hough Transform
CMC	Cumulative Match Characteristic
DCT	Discrete Cosine Transform
DLDA	Direct Linear Discriminant Analysis
DWT	Discrete Wavelet Transform
EER	Equal Error Rate
FAR	False Acceptance Rate
FN	False Negative
FP	False Positive
FRR	False Recognition Rate
HD	Hamming Distance
ICA	Independent Component Analysis
LDA	Linear Discriminant Analysis
LPCC	Linear Prediction Cepstral Coeficientes
NIR	Near Infrared
PCA	Principal Component Analysis
PLR	Pupil Light Reflex

RAD	Rapid Application Development
ROC	Receiver Operating Characteristic
SVM	Support Vector Machine
TN	True Negative
TP	True Positive
WPD	Wavelet Packet Decomposition

Introdução

1.1 A Íris Humana

Na imagem do olho de uma pessoa, a íris é a região anular localizada entre a pupila e o tecido branco que reveste o globo ocular, denominado de esclera. A íris humana é formada por um tecido conjuntivo contendo fibras musculares, vasos sanguíneos e células pigmentares [1].



(a) Imagem frontal do olho humano.



(b) Seção frontal da estrutura da íris.

Figura 1.1: Elementos vistos em uma imagem típica do olho humano.

Conforme mostra a Figura 1.1, anatomicamente a íris é dividida em duas partes denominadas Zona pupilar, que é relativamente plana, porém apresenta dobras (*folds*) que se movimentam de acordo com a contração e a dilatação da íris e a Zona ciliar, que assemelha-se a um conjunto de estrias entrelaçadas em razão de sua vascularização [1] e [2].

Outras variações na aparência da íris são provenientes das criptas (formação irregular

da superfície), de pequenas elevações da superfície e das sardas (concentração de células pigmentadas). Todas estas estruturas constituem o que é denominado de características da íris e são consideradas únicas para cada pessoa [1], [3].

Próximo ao centro da íris encontra-se a pupila, responsável por controlar a quantidade de luz que alcança a retina. Para proteger a retina de uma carga muito intensa de luz dois sistemas musculares controlam o tamanho da íris e consequentemente ajustam o diâmetro da pupila. Conforme descrito em [4], vários fatores podem alterar ou iniciar o processo de movimentação da íris. Basicamente esses movimentos são: (i) a acomodação, que ocorre devido ao processo de foco, (ii) o reflexo pupilar a luz (Pupil Light Reflex - PLR), que é o reflexo da pupila para adaptar o sistema visual ao ambiente e (iii) o hippus, uma oscilação que ocorre constantemente como parte de um processo de convergência disparado pela acomodação e pelo PLR.

1.2 Reconhecimento Biométrico da Íris

O reconhecimento biométrico da íris é um método automático de identificação que usa o padrão aleatório da textura da íris. Modelos digitais, ou *templates* codificam estes padrões e permitem a identificação do indivíduo. Esses modelos digitais inscritos em uma base de dados podem ser comparados e associados com taxas de erro extremamente baixas, próximas de zero [1].

Muitos sistemas de reconhecimento de íris foram propostos, porém o mais conhecido é o sistema desenvolvido por John Daugman [5] que obteve taxas de erro próxima de zero utilizando uma enorme bases de dados - cerca de 632.500 imagens e 200 bilhões de comparações. O protótipo proposto por Wildes et al. [6] usou um conjunto de 520 imagens e não reportou nenhuma falha. Um outro sistema, proposto por Lim et al. [7] utilizou cerca de 5.292 imagens e obteve taxa de reconhecimento de 98,4%.

Normalmente, os sistemas de reconhecimento de íris possuem as seguintes etapas [8]:

- A localização e a segmentação da região da íris na imagem do olho;

- A normalização que corresponde à representação retangular da região anular da íris;
- A codificação que é responsável por analisar e representar a informação contida na íris; e
- E a comparação, onde uma métrica é utilizada para verificar ou identificar os códigos.

Comparado com outros sistemas de biometria, tais como reconhecimento de face, de voz ou de digital, o reconhecimento de íris é o mais confiável [1]. Entretanto, a maioria dos resultados publicados foram obtidos utilizando imagens de íris em condições favoráveis e não levam em conta seu comportamento dinâmico, ou seja, sua variação de área devido ao seu movimento de contração e dilatação [9], [10], [11] e [12].

1.3 Motivação: Deformação da Íris e o Reconhecimento Biométrico

O movimento da íris tem várias consequências. A pressão no tecido da íris durante seu movimento pode fazer com que algumas pequenas regiões se dobram por baixo de outras. Isso significa que pequenas partes do padrão desaparecerão e nenhum modelo de deformação será capaz de representar essa transformação [13].

Outro problema gerado pelo movimento da íris é a falsa rejeição entre códigos correspondentes em condições extremas, onde a textura da íris sob forte compressão produz uma imagem normalizada com muitas diferenças da imagem normalizada em condições normais [12] e [13]. Dessa forma, as regiões não afetadas ou menos afetadas pelos movimentos da íris devem fornecer informações suficientes para o processo de reconhecimento.

A maioria dos métodos de reconhecimento de íris assume o modelo proposto por Daugman [14], denominado *homogeneous rubber sheet*, o qual projeta linearmente a região anular da íris em um região retangular fixa. Esse modelo, segundo Daugman, proporciona a geração de códigos de íris que são invariantes sob distorções elásticas não afins.

Entretanto, Wyatt [2] explicou que o modelo *homogeneous rubber sheet* não representa a verdadeira deformação do tecido da íris e concluiu em seu trabalho que um modelo não linear é mais adequado. Resultados experimentais comprovaram que o método de Wyatt tornou o sistema de reconhecimento mais robusto contra estímulos externos, como a variação da iluminação.

Por sua vez, Wei et al. [15] usaram em seu trabalho um algoritmo para modelar a deformação não linear da íris utilizando uma deformação linear mais um desvio aditivo calculado por uma função Gaussiana.

1.4 Objetivos

O principal objetivo deste trabalho é comprovar e avaliar a influência dos movimentos da íris no processo de reconhecimento biométrico e propor um novo método capaz de reduzir esta influência. O método é baseado no reconhecimento parcial e considera as regiões da íris com maior similaridade, apesar da sua deformação não linear. A proposta foi baseada nos algoritmos de histogramas de gradientes orientados e *Dynamic Time Warping*. Os resultados obtidos com a técnica proposta foram comparados com os resultados do sistema tradicional, implementado inicialmente.

A metodologia baseia-se no Desenvolvimento Rápido de Aplicação (RAD) utilizando o Matlab®. A aplicação é composta por subsistemas que correspondem às etapas típicas dos sistemas de reconhecimento de íris, baseado na implementação realizada por Libor Masek [16].

Para tanto, este trabalho utilizou dois conjuntos distintos de imagens. A base de dados CASIA-IRIS-Lamp, formada por 16.212 imagens com resolução de 640×480 pixels, obtidas de 411 indivíduos diferentes e divididas em 819 classes. Durante o processo de aquisição do conjunto CASIA-IRIS-Lamp uma lâmpada intermitente próxima ao indivíduo foi responsável por introduzir maior variação intraclasse, ou seja, deformações elásticas na textura da íris devido à contração e a dilatação da pupila sob diferentes condições de

iluminação.

O outro conjunto utilizado é formado pelas imagens da base CASIA-IrisV1 que contém 756 imagens de 108 olhos (7 imagens de cada olho), capturadas em duas sessões e com resolução de 320×280 pixels. Neste conjunto a região da pupila foi substituída por uma região circular de intensidade constante para mascarar o efeito da reflexão espelhada da iluminação infravermelha (NIR). Dessa forma, a detecção da borda interna da íris fica mais fácil e com mínimo ou nenhum efeito em outros componentes do sistema de reconhecimento de íris.

1.4.1 Objetivos Específicos deste Trabalho

Os objetivos específicos deste trabalho são:

- Fazer uma pesquisa bibliográfica destacando os principais trabalhos da área e as principais técnicas empregadas em cada etapa de processamento de um sistema de reconhecimento de íris;
- Analisar e simular um sistema de reconhecimento de íris, utilizando técnicas de processamento tradicionais, aplicado em dois banco de imagens; um banco de imagens mais tradicional e outro de imagens com maior variabilidade intraclasse;
- Avaliar a influência dos movimentos da íris no processo de reconhecimento biométrico;
- Apresentar a proposta de uma nova técnica para extração de características persistentes ao movimento da íris; e
- Construir utilizando o Matlab®, o método proposto e realizar todos os testes e simulações necessários para avaliar a eficiência desse método;

1.5 Estrutura do Documento

Esta tese está dividida da seguinte forma:

- *Capítulo 1:* Introdução do assunto deste trabalho, apresentação dos objetivos e da estrutura desta tese;
- *Capítulo 2:* Descreve em detalhes os dois principais métodos de segmentação utilizados nos sistemas de reconhecimento de íris: a transformada de Hough e o operador integro-diferencial. São mostrados outros métodos de segmentação, apresentando o estado da arte das pesquisas nesta área. Descreve a implementação da etapa de segmentação utilizada neste trabalho e apresenta os resultados obtidos com as imagens dos conjuntos CASIA-IRIS-Lamp e CASIA-IrisV1;
- *Capítulo 3:* Apresenta em detalhes o modelo de normalização proposto por Daugman e descreve outros métodos de normalização, apresentando o estado da arte das pesquisas nesta área. Mostra a implementação da etapa de normalização utilizada neste trabalho e apresenta os resultados obtidos com as imagens dos conjuntos CASIA-IRIS-Lamp e CASIA-IrisV1;
- *Capítulo 4:* Descreve em detalhes os filtros de Gabor utilizados por Daugman e o cálculo da distância de Hamming (HD) que também foi usado por Daugman como métrica. Mostra outros métodos de extração de características, apresentando o estado da arte nesta área. Apresenta a implementação da etapa de codificação e comparação utilizada neste trabalho e os resultados obtidos com as imagens dos conjuntos CASIA-IRIS-Lamp e CASIA-IrisV1;
- *Capítulo 5:* Mostra o desempenho do sistema para os dois conjuntos de imagens utilizados. Define o ambiente de decisão e apresenta os resultados dos três experimentos realizados, usando as curvas Receiver Operating Characteristic (ROC) e Cumulative Match Characterist (CMC);
- *Capítulo 6:* Apresenta o método proposto para extração de características permanentes da textura da íris, detalhando o algoritmo utilizado para sua implementação. Finalmente, mostra os resultados experimentais e a comparação entre os algoritmos;

- *Capítulo 7:* Resumo das implementações e dos resultados obtidos, principais conclusões, contribuições, sugestões de trabalhos futuros e artigos publicados.

Segmentação

2.1 Introdução

O primeiro passo para o reconhecimento da íris é a segmentação da imagem, isto é, isolar a região da íris do restante da imagem que contém o olho. O sucesso da segmentação depende da qualidade da imagem adquirida, pois padrões corrompidos da íris podem gerar modelos digitais pouco significativos, resultando em baixa taxa de reconhecimento [5].

Alguns fatores que podem alterar a qualidade da imagem são: a interferência da pálpebra, dos cílios e da reflexão espelhada que ocultam parte da informação contida na textura da íris, o baixo contraste entre a esclera, a íris e a pupila que dificulta ou impossibilita a correta detecção das bordas, além de imagens sem foco que diminui a nitidez e a definição das estruturas da íris.

As duas próximas seções descrevem em detalhes os dois principais métodos de segmentação: A transformada de Hough e o operador integro-diferencial. Em seguida são mostrados outros métodos apresentando o estado da arte das pesquisas e das técnicas utilizadas em segmentação de íris. Depois, mostra-se a implementação utilizada neste trabalho. E finalmente, são apresentados os resultados obtidos usando as imagens dos conjuntos CASIA-IRIS-Lamp e CASIA-IrisV1.

2.2 Transformada de Hough

A maioria das técnicas de segmentação aproximam as bordas da íris e da pupila por círculos e elipses. Dessa forma, a transformada de Hough pode ser utilizada para determinar os parâmetros geométricos desses objetos. Alguns trabalhos que utilizam a aproximação por círculos e variações da transformada de Hough são bem conhecidos [8].

Nesta abordagem, a imagem da região do olho é transformada em um mapa de bordas utilizando, por exemplo, o operador de Canny, como mostra a Figura 2.1. Cada ponto da borda define um conjunto de círculos. Estes círculos são definidos para todos os valores possíveis de raio e são centrados nas coordenadas de cada ponto de borda, de acordo com a Equação (2.1).

$$(x - x_0)^2 + (y - y_0)^2 = r^2 \quad (2.1)$$

onde x_0 e y_0 são as coordenadas do centro do círculo, r é o raio do círculo e x e y são as coordenadas de um ponto pertencente ao círculo.

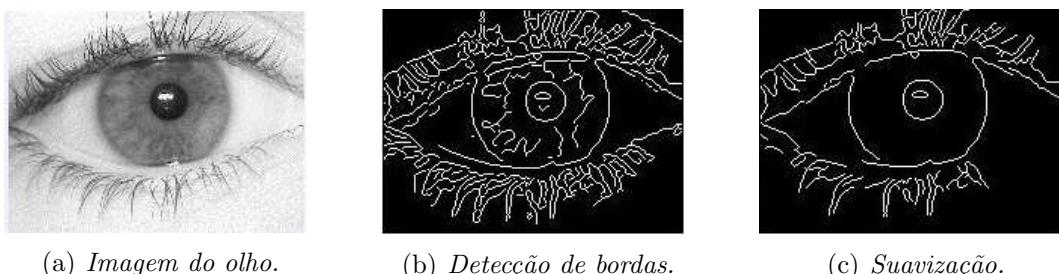


Figura 2.1: *Detecção de bordas pelo método de Canny.*

Os pontos da equação que pertencem à cada possível círculo recebe um voto no espaço acumulador de Hough. O ponto máximo no espaço de Hough corresponde às coordenadas do centro e ao raio do melhor círculo definido pelo mapa de bordas, conforme mostra a Figura 2.2, adaptada de [17].

Alguns problemas podem ser encontrados na aplicação deste método. A imagem de bordas gerada é sensível à escolha de um limiar. Dessa forma alguns pontos críticos podem

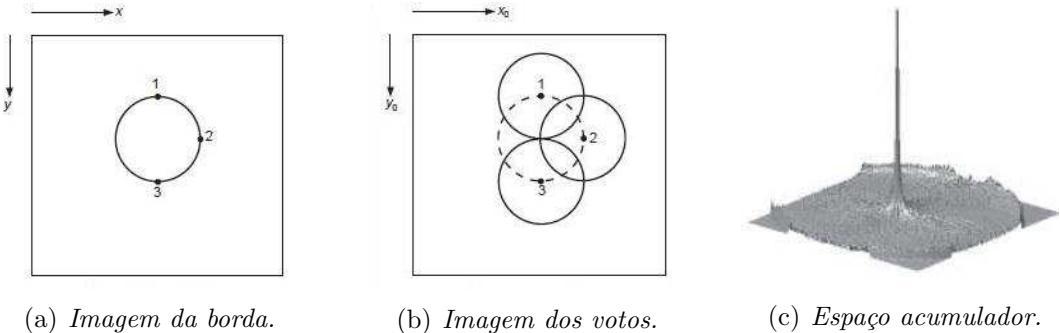


Figura 2.2: Transformada de Hough para círculos.

ser removidos resultando em falhas na detecção dos círculos. Outro problema é o seu custo computacional impossibilitando aplicações em tempo real [17].

2.3 Operador Integro-diferencial

Daugman usou o operador integro-diferencial para localizar a região circular da íris, da pupila e também dos arcos superior e inferior das pálpebras [1]. O operador integro-diferencial é definido como mostrado na Equação (2.2).

$$\max_{(r,x_0,y_0)} \left| G_\sigma(r) * \frac{\partial}{\partial r} \oint_{r,x_0,y_0} \frac{I(x,y)}{2\pi r} ds \right| \quad (2.2)$$

em que: $*$ representa a operação de convolução, $G_\sigma(r)$ é uma função Gaussiana de suavização com escala σ , $I(x,y)$ é a imagem do olho, r é o raio de busca e s é o contorno do círculo, descrito por r, x_0, y_0 .

Variando o raio e a posição do centro do contorno circular, o operador integro-diferencial busca a máxima mudança no valor dos pixels do caminho. O operador é aplicado iterativamente com uma quantidade de suavização progressivamente reduzida. O contorno das pálpebras são localizados de maneira semelhante, com o caminho de integração de um arco.

Apesar de não existir problemas de escolha de limiar, o operador integro-diferencial é mais sensível à ruído e pode falhar, por exemplo, quando a imagem apresenta reflexos [16].

2.4 Estado da Arte

Outras abordagens para a segmentação também são encontradas. Pereira et al. [18] utilizaram algoritmo genético associado à Transformada Circular de Hough (CHT) para encontrar os parâmetros dos círculos da íris e da pupila com um tempo de processamento adequado, tornando o processo menos oneroso computacionalmente. Lili e Mei [19] utilizaram os principais picos em um histograma para distinguir a posição da pupila, da íris e da esclera. Xu et al. [20] dividiram a imagem do olho em uma malha retangular e utilizaram a intensidade mínima média para gerar um limiar de binarização e encontrar a pupila. A busca continua fora da região da pupila para encontrar a borda da íris.

Bonney et al [21] encontraram a pupila utilizando operações com bits menos significativos, erosão e dilatação. A borda da íris é encontrada calculando o desvio padrão nas direções horizontal e vertical e as bordas da pupila e da íris são modeladas como elipses. El-Bakry [22] propôs uma rede neural para segmentar a íris. He et al. [23] utilizaram o método de Viola para a classificação em cascata e detectaram a pupila, seguido de um ajuste ótimo para determinar as bordas.

Alguns assuntos relacionados a segmentação ainda permanecem sendo estudados, como por exemplo, o tratamento não circular das bordas da íris e da pupila, o tratamento de oclusões por cílios, pálpebras e reflexos e a segmentação robusta onde as imagens dos olhos mostram o uso de lentes de contato e óculos.

Em [5], Daugman utilizou a técnica de contorno ativo para modelar com maior precisão as bordas da pupila e da íris. Kong and Zhang [24] apresentaram um método para verificar a presença dos cílios e das reflexões especulares. Segundo eles, os cílios podem ser diferenciados da textura da íris ou obstruir parte da informação da íris. Os resultados obtidos apresentaram uma melhora de 3% na Taxa de Erro Igual (EER). Huang et al. [12] utilizaram um método baseado em fusão de bordas e regiões de informação para diminuir o efeito do ruído ou oclusões devido as pálpebras, os cílios e as reflexões.

2.5 Implementação

Foram utilizados neste trabalho o operador integro-diferencial, adaptado da implementação disponibilizada por Anirudh S. [25], e a transformada circular de Hough, baseada no sistema proposto por Libor Masek [16], por se tratarem de abordagens mais tradicionais de detecção.

Foi acrescentado uma etapa de redução do espaço acumulador para melhorar o desempenho do sistema construído e diminuir o tempo de processamento da transformada de Hough. Esta etapa reduz sucessivamente o espaço acumulador desconsiderando regiões com poucos votos [17].

Para a detecção das pálpebras Libor Masek utilizou a transformada de Hough linear que encontra uma reta correspondente à borda da pálpebra superior e uma reta correspondente à borda da pálpebra inferior. Uma terceira reta é então desenhada horizontalmente interceptando a primeira no ponto de borda da íris mais próximo à pupila. Este procedimento é realizado para as pálpebras superior e inferior e são excluídas as regiões acima da reta horizontal referente à pálpebra superior e abaixo, referente à pálpebra inferior. Este processo, adaptado de [16], é mostrado na Figura 2.3.

Pode acontecer de não existir em algumas imagens a oclusão da íris pelas pálpebras. Assim, se o máximo valor no espaço de Hough for menor do que um limiar preestabelecido, então, nenhuma reta é identificada e isso representa uma não oclusão. Além disso, uma reta só é considerada se está fora da região da pupila e dentro da região da íris.

Além disso, Libor Masek [16] utilizou uma técnica baseada no estabelecimento de um limiar para isolar os cílios. Ele considerou que os cílios são sempre mais escuros quando comparados com o resto da imagem. Assim, todos os pixels da imagem com tom de cinza mais escuro do que o limiar estabelecido são considerados pixels pertencentes aos cílios e são excluídos.

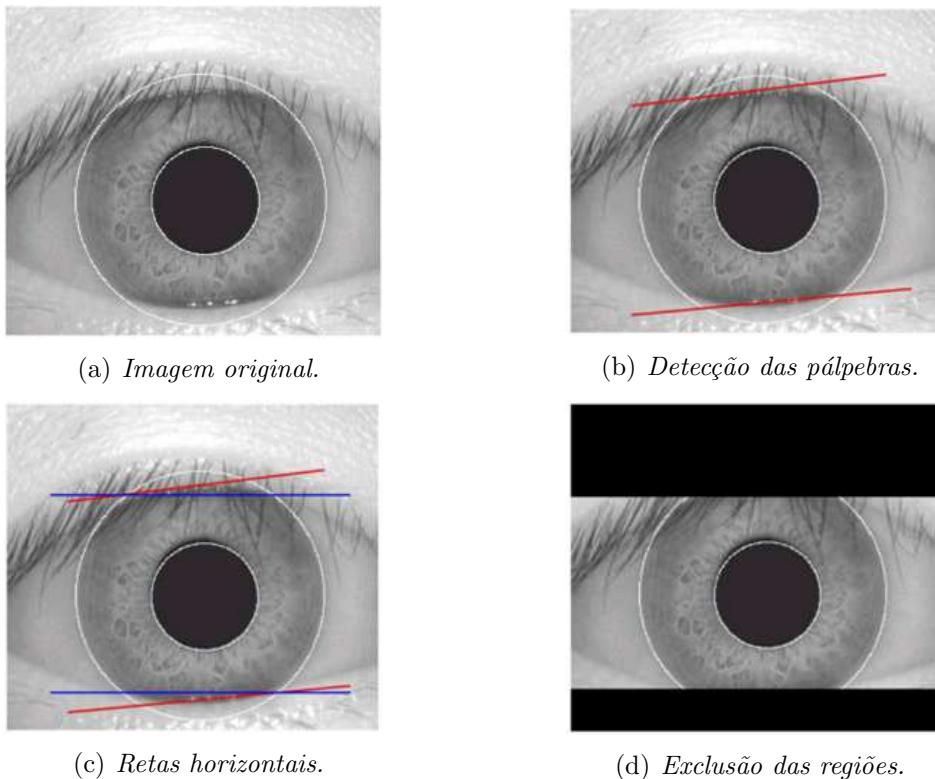


Figura 2.3: *Processo de exclusão das pálpebras.*

2.6 Resultados

Como primeiro estágio, a segmentação da íris é muito importante para o sistema de reconhecimento. Se a região da íris não for segmentada corretamente, possivelmente os ruídos causados pelos cílios, pálpebras, reflexões especulares e outras regiões não pertencentes à íris resultarão no deterioramento da performance do sistema.

Para o sistema que utiliza a transformada de Hough, os raios de busca da pupila e da íris são inseridos manualmente, assim como os limiares para o mapa de bordas e para a detecção dos cílios. Para o banco de imagens CASIA-IrisV1, o raio de busca da pupila variou de 28 a 75 pixels e o da íris variou de 80 a 150 pixels. Os mesmos valores foram utilizados para o banco de imagens CASIA-IRIS-Lamp.

O limiar para o mapa de bordas utilizado foi 0,2 e, conforme a implementação de Libor Masek, o gradiente na direção horizontal do mapa de bordas foi desconsiderado,

pois normalmente as pálpebras ficam alinhadas nesta direção e nem todos os pontos são necessários para detectar o círculo, tornando a transformada de Hough mais rápida. O limiar utilizado para separar os cílios foi de 100 e 50 para os conjuntos CASIA-IrisV1 e CASIA-IRIS-Lamp, respectivamente.

Utilizando estes valores e por inspeção visual o sistema segmentou corretamente 85% e 75% das imagens dos conjuntos CASIA-IrisV1 e CASIA-IRIS-Lamp, respectivamente. A detecção dos cílios e das pálpebras apresentou resultados satisfatórios para a maioria das imagens, como mostrado na Figura 2.4.

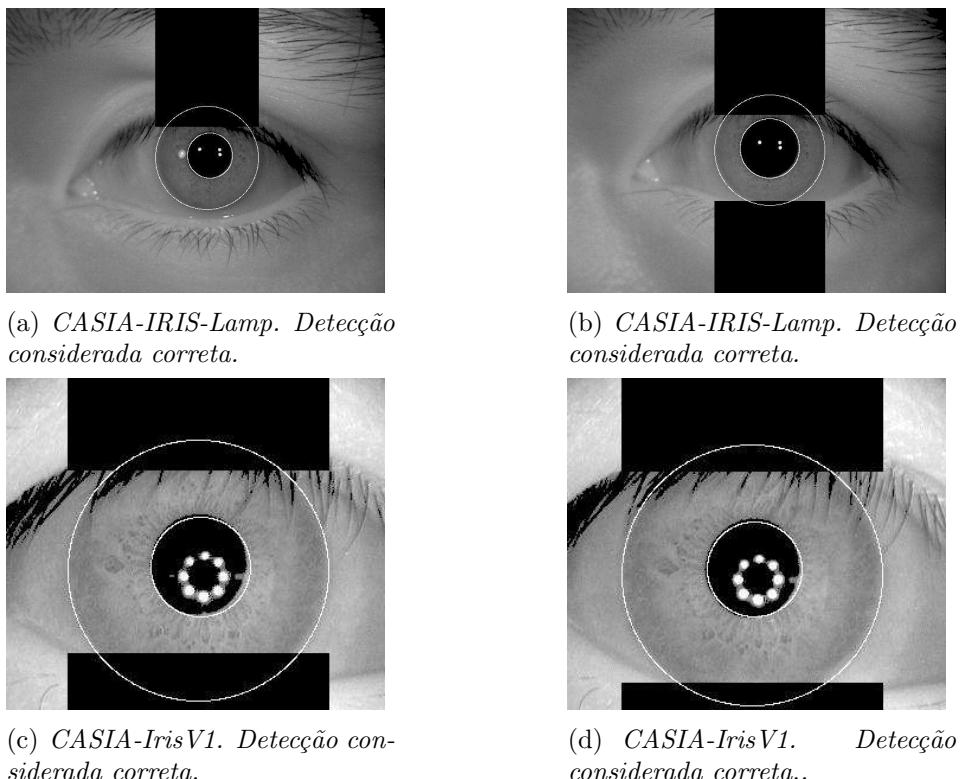
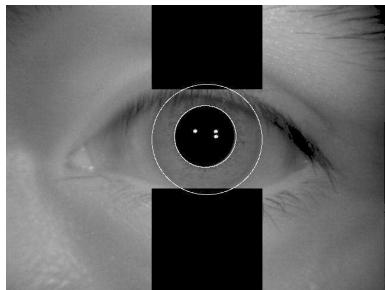


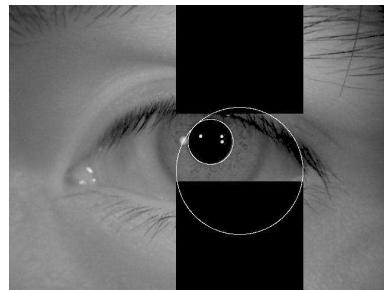
Figura 2.4: *Imagens da íris segmentada.*

A Figura 2.5 mostra algumas falhas na segmentação. Geralmente a segmentação falha nas imagens com baixo contraste entre a pupila e a íris e entre a íris e a esclera. Entretanto, problemas mais graves ocorrem quando os cílios e as pálpebras não são detectados corretamente e quando a forma circular não corresponde à forma da íris e da pupila, pois nestes casos, parte da informação da íris é perdida, comprometendo as etapas posteriores

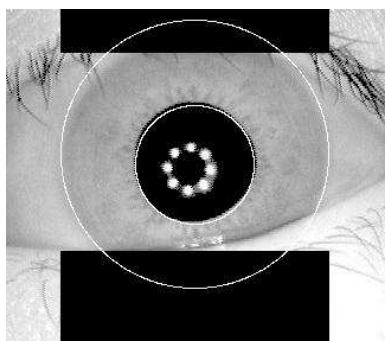
no processo de reconhecimento.



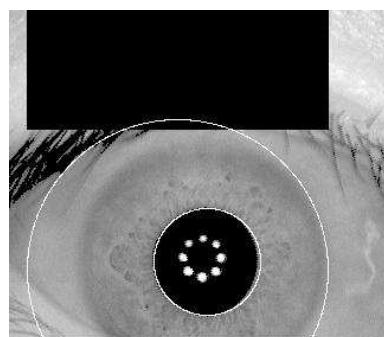
(a) *CASIA-IRIS-Lamp.* Cílios e pálpebras não foram detectados corretamente.



(b) *CASIA-IRIS-Lamp.* Baixo contraste entre íris e esclera.



(c) *CASIA-IrisV1.* Cílios e pálpebras não foram detectados corretamente.



(d) *CASIA-IrisV1.* Baixo contraste entre a íris e a esclera.

Figura 2.5: *Falhas no processo de segmentação.*

O sistema que utilizou o operador integro-diferencial não apresentou resultados satisfatórios. Além do tempo excessivo de processamento, a taxa de segmentação correta para os conjuntos de imagens utilizados foi na faixa de 45 à 52%. Essa taxa foi considerada muito baixa.

2.7 Considerações Finais do Capítulo

Neste capítulo foram abordados o operador integro-diferencial e a transformada de Hough, principais técnicas de segmentação, responsáveis por isolar a região da íris do restante da imagem que contém o olho. Outras abordagens para a etapa de segmentação foram apresentadas na seção 2.4.

Na seção 2.5 foram definidas as estratégias de detecção das bordas da íris e da pupila e o tratamento de oclusões. E finalmente, a seção 2.6 mostra os resultados obtidos na segmentação das imagens pertencentes aos bancos CASIA-IrisV1 e CASIA-IRIS-Lamp.

3.1 Introdução

Após a segmentação, o próximo passo é organizar a informação contida na íris de forma a permitir futuras verificações e identificações. Entre as imagens a serem comparadas pode existir um grande número de inconsistências dimensionais, como por exemplo, a deformação da íris causada pelo reflexo pupilar à luz, a variação da distância da imagem, a rotação da câmera, a inclinação da cabeça e a rotação dos olhos [16].

A grande maioria dos estudos e dos sistemas propostos utilizam a normalização para produzir imagens com dimensões constantes [15]. Dentre os métodos de normalização mais utilizados está o modelo *homogeneous rubber sheet* proposto por Daugman [14]. Neste modelo, o sistema assume que as características utilizadas no processo de reconhecimento estão na mesma posição espacial, inclusive para imagens sob diferentes condições de iluminação, rotação e distância da câmera.

A próxima seção descreve o modelo de normalização proposto por Daugman, pois este trabalho utiliza uma versão deste modelo. Em seguida, são mostrados outros métodos apresentando o estado da arte das pesquisas e das técnicas utilizadas em normalização da íris. Depois, descreve-se a implementação utilizada neste trabalho. E, finalmente, são apresentados os resultados obtidos com as imagens dos conjuntos CASIA-IRIS-Lamp e CASIA-IrisV1.

3.2 O Modelo Homogeneous Rubber Sheet

Como o próprio nome diz, o modelo *homogeneous rubber sheet* proposto por John Daugman, considera a região da íris como se esta fosse um anel de borracha. Assim, para a mesma imagem em instantes diferentes, os pontos localizados na direção radial entre a borda da pupila e a borda da íris podem ter deslocamentos proporcionais à variação do raio da pupila e da íris, nesta mesma direção [14]. Esse método utiliza coordenadas polares adimensionais conforme mostra a Figura 3.1.

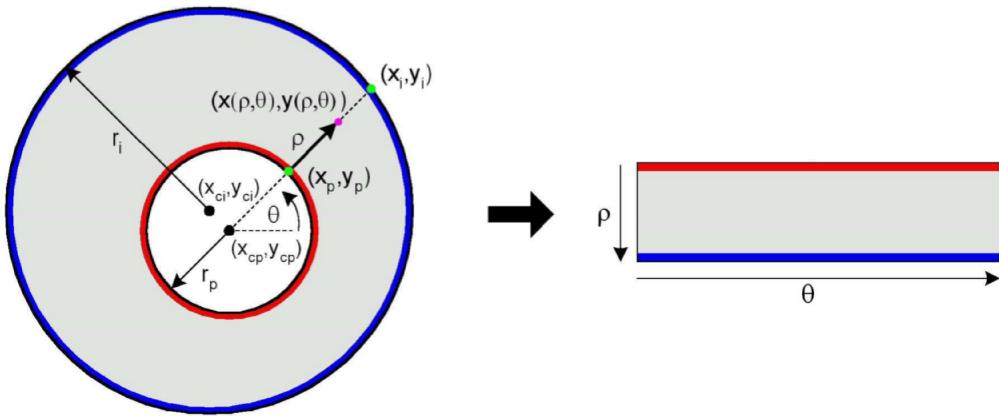


Figura 3.1: Representação retangular da região da íris proposta por John Daugman.

O método proposto consiste em re-mapear a região da íris passando de coordenadas cartesianas (x, y) para coordenadas polares adimensionais (ρ, θ) , onde ρ pertence ao intervalo $[0, 1]$ e θ representa um ângulo no intervalo $[0, 2\pi]$. A representação polar normalizada é modelada utilizando-se as Equações (3.1) - (3.5).

$$I(x(\rho, \theta), (y(\rho, \theta)) \rightarrow I(\rho, \theta) \quad (3.1)$$

$$\begin{cases} x(\rho, \theta) = x_p(\theta) + \rho(x_i(\theta) - x_p(\theta)) \\ y(\rho, \theta) = y_p(\theta) + \rho(y_i(\theta) - y_p(\theta)) \end{cases} \quad (3.2)$$

$$\begin{cases} x(\rho, \theta) = (1 - \rho)x_p(\theta) + \rho x_i(\theta) \\ y(\rho, \theta) = (1 - \rho)y_p(\theta) + \rho y_i(\theta) \end{cases} \quad (3.3)$$

com

$$\begin{cases} x_p(\theta) = x_{cp} + r_p \cos(\theta) \\ y_p(\theta) = y_{cp} + r_p \sin(\theta) \end{cases} \quad (3.4)$$

$$\begin{cases} x_i(\theta) = x_{ci} + r_i \cos(\theta) \\ y_i(\theta) = y_{ci} + r_i \sin(\theta) \end{cases} \quad (3.5)$$

em que: $I(x, y)$ é a imagem da região da íris, (x, y) são coordenadas cartesianas originais, (ρ, θ) são coordenadas polares normalizadas correspondentes, (x_p, y_p) e (x_i, y_i) são coordenadas da borda da pupila e da íris na direção θ , enquanto (x_{cp}, y_{cp}) e r_p são coordenadas do centro da pupila e (x_{ci}, y_{ci}) e r_i são coordenadas do centro da íris.

3.3 Estado da Arte

Outros pesquisadores notaram que a dilatação da íris afeta a qualidade da correspondência entre as imagens de um mesmo olho e, apesar de uma boa aproximação, o modelo *homogeneous rubber sheet* não descreve o verdadeiro movimento da íris por se tratar de um movimento não linear [15], [9] e [13]. Dessa forma, é necessário modelar a deformação da íris para, então aplicar a normalização não linear. Vários modelos de deformação não linear da íris foram propostos [12], [13] e [26].

Existem ainda alguns trabalhos que evitam os tradicionais processos de normalização. Birgale et. al. [27] propuseram a utilização de diferentes máscaras para filtrar as informações contidas na íris e compara seu método com o proposto por Daugman. Li e Xie [28] propuseram um método baseado na extração parcial da informação contida na íris. Eles utilizaram imagens isométricas, consideraram a posição do centro da pupila e o tamanho do raio da íris fixos para coletar pontos equidistantes.

3.4 Implementação

A etapa de normalização utilizada neste trabalho é a mesma desenvolvida por Libor Masek [16] onde, como mostra a Figura 3.2, uma determinada quantidade de pontos é selecionada uniformemente ao longo de cada linha radial, considerando o centro da pupila como ponto de referência. Essa quantidade de pontos representa a resolução radial que define a dimensão vertical da representação retangular. A quantidade de linhas radiais representa a resolução angular que define a dimensão horizontal da representação retangular.

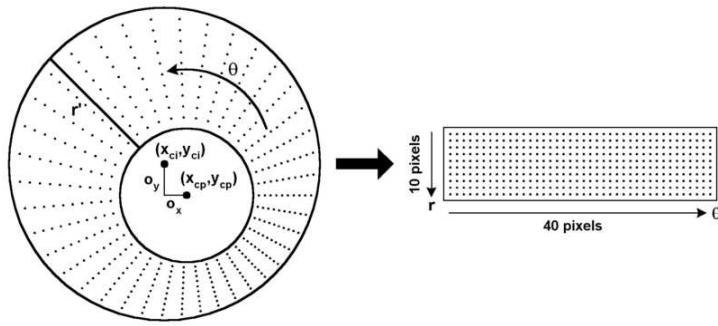


Figura 3.2: Normalização com resolução radial igual a 10 pixels e resolução angular igual a 40 pixels.

Como as regiões da pupila e da íris podem ser não concêntricas, Libor Masek [16] sugeriu, a utilização da Equação (3.6) para redimensionar os pontos dependendo do valor do ângulo θ .

$$r' = \sqrt{\alpha\beta^2 - \alpha} - r_I^2 \quad (3.6)$$

com $\alpha = o_x^2 + o_y^2$ e $\beta = \cos(\pi - \arctan(\frac{o_y}{o_x})) - \theta$.

A Equação (3.6) fornece o raio da região da íris em função do ângulo θ , em que o_x e o_y representam o deslocamento do centro da pupila em relação ao centro da íris, r' é a distância entre as bordas da pupila e da íris para um determinado valor de θ e r_I é o raio da íris.

Para garantir uma dimensão constante na representação retangular, é selecionado um número constante de pontos ao longo de cada linha radial, independente da largura da

região entre as bordas da pupila e da íris para determinado ângulo.

O método utilizado para a localização da íris pode não apresentar uma precisão perfeita, assim, para tentar evitar que áreas não pertencentes à íris sejam utilizadas na representação normalizada, são desconsiderados os pontos da borda da pupila e da íris.

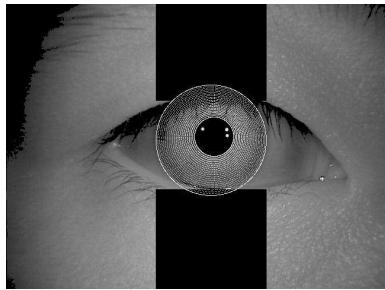
Uma vez obtidas as posições radial e angular dos pontos selecionados, são encontradas as coordenadas cartesianas correspondentes, utilizando a Equação (3.3). A saída normalizada é gerada ao extrair os valores de intensidade de tons de cinza da imagem original nas posições cartesianas obtidas.

Segundo Daugman [1] e [14], esse procedimento, além de considerar o fato da pupila e da íris não serem concêntricas, também elimina os problemas da dilatação da pupila e do zoom da imagem, gerando uma saída representativa da região da íris com dimensões constantes. Porém, este método não compensa as inconsistências rotacionais da imagem do olho. Neste trabalho, seguindo o procedimento adotado por Libor Masek [16], tais inconsistências são tratadas na fase de comparação, onde a *template* de uma íris é deslocada na direção de θ até que as *templates* das duas íris fiquem alinhados.

Para marcar os pixels pertencentes às pálpebras e aos cílios, que foram detectados na etapa de localização e interferem na região da íris, uma máscara de ruídos é gerada com a mesma dimensão da representação retangular da íris. Para gerar esta máscara os pontos que foram identificados como ruído na etapa de segmentação recebem o valor 1, enquanto todos os outros pixels são representados pelo valor 0.

3.5 Resultados

A Figura 3.3 mostra o resultado da etapa de normalização. A Figura 3.4 mostra a normalização da imagem do mesmo olho, porém observa-se que a pupila da imagem superior é menor e que o processo de normalização retorna imagens retangulares com dimensões 20×240 pixels, constantes para as duas íris. Nesta etapa, segundo Daugman [1], a única inconsistência entre as imagens é a rotacional que será corrigida no etapa de comparação.



(a) Pixels selecionados na imagem original para a geração da representação retangular da íris.

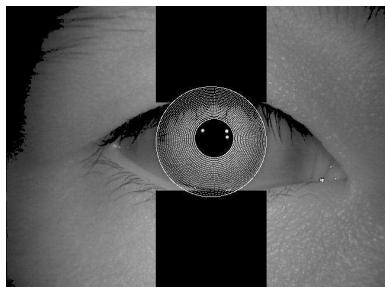


(b) Representação retangular da região da íris com dimensões de 20×240 pixels.



(c) Máscara de ruídos com dimensões de 20×240 pixels. A parte branca representa as regiões que têm interferência das pálpebras e cílios.

Figura 3.3: Resultado da aplicação do algoritmo de normalização em uma imagem.



(a) Imagem da íris com pupila menor.



(b) Representação retangular da região da íris com dimensões de 20×240 pixels.



(c) Máscara de ruídos com dimensões de 20×240 pixels. A parte branca representa as regiões que têm interferência das pálpebras e cílios.



(e) Representação retangular da região da íris com dimensões de 20×240 pixels.



(f) Máscara de ruídos com dimensões de 20×240 pixels. A parte branca representa as regiões que têm interferência das pálpebras e cílios.

Figura 3.4: Normalização das imagens de duas íris em instantes diferentes.

3.6 Considerações Finais do Capítulo

Neste capítulo foi abordado o modelo de normalização *homogeneous rubber sheet* proposto por Daugman [14]. Outras abordagens para a etapa de normalização foram apresen-

tadas na seção 3.3.

Na seção 3.4 foram definidas a resolução radial e a resolução angular do processo de amostragem. Foi apresentada a representação retangular e a máscara de ruído. E, finalmente, a seção 3.5 mostra os resultados obtidos na normalização das imagens pertencentes aos bancos CASIA-IrisV1 e CASIA-IRIS-Lamp.

Codificação e Comparação

4.1 Introdução

A análise da textura da íris é a área mais popular da pesquisa em reconhecimento biométrico. Basicamente, a maioria dos trabalhos utilizam algum tipo de filtro para obter uma representação binária da íris, chamada de código da íris ou então geram um vetor com características da íris representadas por números reais. Para aumentar a precisão apenas as características mais significativas devem ser codificadas e comparadas [29].

A comparação é realizada utilizando uma métrica capaz de medir o grau de similaridade entre os códigos. A comparação intraclasses ocorre quando os códigos da mesma íris são comparados, e a comparação interclasses ocorre quando os códigos de íris diferentes são comparados. Para esses dois casos, a métrica deve retornar uma faixa de valores distintos e separados para que a decisão de aceitar ou rejeitar a comparação tenha alto grau de confiabilidade [1] e [29].

A próxima seção descreve os filtros de Gabor utilizados por Daugman, pois este trabalho utiliza uma versão deste modelo. Depois é mostrado o cálculo da distância de Hamming que também foi usada por Daugman como métrica. Em seguida, são descritos outros métodos apresentando o estado da arte das pesquisas e das técnicas utilizadas em extração de características da íris e a implementação utilizada neste trabalho. E, finalmente, são apresentados os resultados obtidos com as imagens dos conjuntos CASIA-IRIS-Lamp e

CASIA-IrisV1.

4.2 Filtros de Gabor

Os filtros de Gabor são um conjunto de funções Gaussianas moduladas por funções sinusoidais complexas, bidimensionais e capazes de extrair atributos que caracterizam diferentes tipos de texturas descritas pela frequência e orientação. A Equação (4.1) representa uma família de funções de Gabor.

$$G(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} e^{[-\frac{1}{2}(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2})]} e^{(2\pi jfx)} \quad (4.1)$$

Na Equação (4.1), a parte real e a imaginária são conhecidas, respectivamente, como componente de simetria par e componente de simetria ímpar. A parte real é representada por uma cossenoide modulada por uma Gaussiana e a parte imaginária é representada por uma senoide também modulada por uma Gaussiana. A frequência central é determinada pela frequência da exponencial complexa e a largura de faixa do filtro é determinada pela largura da Gaussiana [16].

Daugman utilizou uma versão 2D do filtro de Gabor para codificar a informação contida na textura da íris. O filtro de Gabor 2D no domínio (x, y) da imagem é mostrado na Equação (4.2).

$$G(x, y) = e^{-\pi[(x-x_0)^2/\alpha^2 + (y-y_0)^2/\beta^2]} e^{-2\pi i[u_0(x-x_0) + v_0(y-y_0)]} \quad (4.2)$$

em que: (x_0, y_0) é uma a posição na imagem, (α, β) a largura e o comprimento eficaz e (u_0, v_0) é a modulação que possui frequência espacial $\omega_0 = \sqrt{u_0^2 + v_0^2}$.

Entretanto, conforme descrito em [16], o filtro de Gabor possui algumas limitações. Sempre que a largura de faixa do filtro de Gabor for maior do que uma oitava, a componente de simetria par irá possuir uma componente dc devido à sobreposição das caudas das gaussianas. Uma alternativa para resolver esse problema é o filtro Log-Gabor.

Neste caso, a Gaussiana é representada em uma escala logarítmica e assim, é possível obter uma componente dc igual a zero para qualquer largura de faixa utilizada. A resposta em frequência do filtro Log-Gabor é obtida pela Equação (4.3).

$$G(f) = e^{\frac{-(\log(f/f_c))^2}{2(\log(\sigma/f_c))^2}} \quad (4.3)$$

em que: f_c é a frequência central e σ é a largura de faixa do filtro.

4.3 Distância de Hamming

Diversas métricas podem ser utilizadas para comparação. As mais populares são a distância de Hamming (HD), a distância euclidiana ponderada e a correlação normalizada.

Vários trabalhos utilizam a distância de Hamming, por exemplo, os de John Daugman [1], de Vatsa et al. [30] e de Li Ma et al. [3]. Essa distância fornece uma medida da quantidade de bits que são comuns entre duas *templates* comparadas. Ela é definida como a soma dos bits discordantes ao longo do número total de bits N .

$$HD = \frac{1}{N} \sum_{j=1}^N X_j \oplus Y_j \quad (4.4)$$

em que: X_j e Y_j são os bits dos dois padrões e \oplus é a operação de ou exclusivo.

Se dois padrões de bits são completamente independentes, tais como modelos gerados a partir de diferentes íris, a distância de Hamming entre os dois padrões deve ser igual a 0,5. Isso ocorre porque a independência entre os dois padrões de bits é totalmente aleatória, com 50% de chance para qualquer bit 0 ou 1. Portanto, metade dos bits vão concordar e metade vão discordar entre os dois padrões. Se dois padrões são derivados das mesmas íris, a distância de Hamming entre eles será próxima de 0, uma vez que eles são altamente correlacionados e os bits devem concordar entre os dois códigos de íris [1] e [16].

A distância euclidiana ponderada pode ser utilizada quando as *templates* são compostas de valores inteiros. Ela fornece uma medida da similaridade de um conjunto de valores

provenientes de dois *templates*. Esta técnica foi empregada por Zhu et al. [31]. A correlação normalizada foi utilizada como métrica para comparação de duas *templates* por Wildes et al. [26] e por Kim et al [32].

4.4 Estado da Arte

4.4.1 Análise e representação da textura da íris

Muitos tipos de filtros já foram sugeridos para a extração das características da íris. Sun et al [33] utilizaram o filtro Gaussiano convoluído com o vetor gradiente da imagem da íris. Eles quantizaram o ângulo da saída do filtro em seis quadrantes e não em quatro com fez Daugman.

Ma et al. [34] utilizaram a transformada de *wavelet* para desenvolver um código binário a partir da informação contida na região mais interna da íris. O método proposto é comparado com outros métodos dos mesmos autores e com os métodos de Daugman [1], Wildes [26], e Boles e Boashash [35], sem a detecção da pálpebra e dos cílios. Como resultado é relatado que o método atingiu 0,07% de taxa de erro global, e 0,09% de erro para a comparação entre as imagens adquiridas com aproximadamente um mês de diferença.

Chenhong e Zhaoyang [36] convoluíram a imagem da íris com um filtro Laplaciano-Gaussiano. Eles utilizaram esse filtro para encontrar pontos na imagem que são relativamente mais escuros do que as regiões circundantes. Um código de íris é então construído com base na presença ou na ausência de manchas.

Chou et. al. [37] utilizaram filtros derivados do Laplaciano-Gussiano. Uma medida da distância entre duas imagens da íris é então representada pela relação entre o número de pixels correspondentes em que os mapas de borda discordam dividido pelo número no qual eles concordam. Eles sugerem um algoritmo genético para encontrar os parâmetros do filtro.

Yao et al. [38] utilizaram filtros Log-Gabor modificados, pois os filtros Log-Gabor são

estritamente passa banda e os filtros de Gabor não são. Eles afirmaram que os filtros de Gabor comuns representam fielmente componentes naturais de alta frequência e que a utilização do filtro modificado melhora a EER de 0,36% para 0,28%.

Alguns trabalhos recomendam a utilização da Wavelet Packet Decomposition (WPD) ao invés da transformada *wavelet* padrão (DWT). Rydgren et al. [39] afirmaram que a abordagem da WPD pode ser uma boa alternativa, uma vez que oferece uma divisão mais detalhada do plano de frequência. Eles consideraram vários tipos diferentes de ondas: Haar, Daubechies, bi-ortogonal, *coiflet* e *symlet* e relataram que o desempenho para a *wavelet* Gabor é superior. Os resultados experimentais foram obtidos utilizando 82 imagens de um total de 33 íris diferentes.

Krichen et al. [40] também consideraram a WPD. Eles relataram que para seu próprio conjunto de imagens capturadas com luz visível, o desempenho da WPD é melhor quando comparado com a abordagem clássica DWT, mas que, para o conjunto de imagem CASIA 1 que utiliza luz infravermelha, os dois métodos têm desempenho similar.

O desempenho de um sistema de reconhecimento de íris não depende somente do filtro escolhido, mas também dos parâmetros e das escalas utilizadas no filtro. Thornton et al. [41] realizaram uma comparação detalhada com sete tipos diferentes de filtros e relataram que *wavelets* de Gabor são filtros de banda mais discriminantes para os padrões da íris. Porém, essas *wavelets* são altamente dependentes dos parâmetros que determinam a sua forma específica.

Huang e Hu [42] apresentaram uma abordagem para encontrar a escala correta para a análise de imagens da íris. Eles realizaram uma análise *wavelet* em múltiplas escalas para encontrar cruzamentos por zero e extremos locais e determinaram que a escala apropriada para uma transformada *wavelet* deve estar entre 0 e 6, minimizando a distância de Hamming.

Outros pesquisadores também adotaram *wavelets*, mas em vez de utilizar a saída da transformada para construir um vetor binário de característica, mantiveram como saída um vetor de valores reais e utilizaram métricas diferentes da distância de Hamming para comparação.

Sanchez-Avila e Sanchez-Reillo [43] codificaram a textura da íris considerando um conjunto de sinais 1D a partir de regiões anulares da íris. A transformada *wavelet* é realizada neste sinal 1D e uma representação *zero-crossing* é extraída. A distância euclidiana dos valores de características originais, a distância de Hamming dos valores de características binarizados e uma medida de distância mais diretamente relacionadas com a representação de cruzamento por zero são comparadas. Eles concluíram que a abordagem de Daugman, usando filtros de Gabor, possui melhor desempenho do que a abordagem de passagens por zero. Eles também relataram que a abordagem dos cruzamentos por zero é mais rápida do que a abordagem de Daugman.

Alim e Sharkas [44] testaram quatro métodos diferentes: coeficientes de fase Gabor, histograma de coeficientes de fase, decomposição em quatro e seis níveis da *wavelet* Daubechies, e a transformação de cosseno discreta (DCT). A saída de cada método de extração de característica é então usada para treinar uma rede neural. O melhor desempenho, com 96% de reconhecimento, foi encontrado utilizando a DCT e uma rede neural com 50 neurônios de entrada e 10 neurônios escondidos.

Jang et al. [45] utilizaram a transformada *wavelet* de Daubechies para compor a imagem em sub-bandas. A média, a variância, o desvio padrão e a energia encontradas a partir do histograma de nível de cinza das sub-bandas são utilizados como vetores de características. Eles testaram dois algoritmos de correspondência diferentes e concluíram que o método support vector machine (SVM) tem melhor desempenho do que a distância euclidiana simples.

Um outro grupo de trabalho combinou os dois diferentes tipos de vetores de características. Por exemplo, Sun et al. [46] utilizaram um sistema em cascata em que a primeira fase é um classificador tradicional baseado no trabalho de Daugman. Se a semelhança entre as íris está acima de um limite é aceita a verificação. Caso contrário, se a similaridade está abaixo de um limiar é rejeitada a verificação. Se a semelhança está entre os limiares, a decisão é passada para um segundo classificador baseado em cruzamentos por zero.

Existem métodos estatísticos que podem ser utilizados como uma alternativa ou complemento à *wavelets* na extração de características. Huang et al. [47] utilizaram análise de

componentes independentes (ICA) para a extração de características. Dorairaj et al. [48] usaram análise de componentes principais (PCA) e análise de componentes independentes (ICA). No entanto, ao contrário de Huang et al. [47], eles aplicaram o PCA e a ICA em toda a região da íris ao invés de pequenas janelas.

Ma et al. [49] utilizaram uma variante do filtro Gabor em duas escalas para analisar a textura da íris. Eles usaram discriminante linear de Fisher para reduzir as 1.536 características originais dos filtros de Gabor para um vetor de características de tamanho 200. Os resultados experimentais mostraram que o método proposto apresenta resultados tão bons como a implementação do algoritmo proposto por Daugman. Os resultados experimentais são apresentados utilizando curvas ROC, com intervalos de confiança de 95%.

Chu et al. [50] utilizaram Linear Prediction Cepstral Coeficientes (LPCC)e Linear Discriminant Analysis (LDA) para extrair as características da íris. LPCC é um algoritmo que é comumente utilizado para a extração de características em sinais de voz. Para correspondência, eles usaram uma rede neural probabilística otimizada.

Algumas pesquisas consideram as deformações não-lineares da íris que ocorrem quando a pupila dilata. Thornton et al. [13] encontraram a estimativa máxima de probabilidade a posteriori dos parâmetros da deformação relativa entre um par de imagens. Eles utilizam dois métodos para extraír informações de textura da imagem: *Wavelet* de fase e filtros de correlação. Os testes desse algoritmo é realizado utilizando os banco de dados CASIA 1 e Carnegie Mellon University. Os resultados mostraram que a estimativa da deformação relativa entre as duas imagens melhora o desempenho, não importa qual o banco de dados é usado, independentemente se são utilizados códigos de fase *wavelet* ou filtros de correlação.

Como citado anteriormente, Wei et al. [15] modelaram o movimento não linear da íris como uma soma de estiramento linear e um termo de desvio Gaussiano. Esse modelo também resulta em melhoria no modelo linear simples.

Alguns trabalhos relataram métodos únicos de extração de características que não seguem as principais tendências. Takano et al. [51] evitaram o uso de qualquer tipo transformada. Eles usaram redes neurais e a própria imagem normalizada da íris como vetor de característica.

Ives et al. [52] compararam os histogramas normalizados das imagens segmentadas. Segundo eles, a estreita correspondência entre os histogramas permite a verificação de identidade. Uma motivação para esta abordagem é que o histograma correspondente evita a necessidade de utilizar o código da íris, e assim pode permitir um reconhecimento mais rápido. No entanto, o EER relatado a partir de experiências usando o conjunto de dados CASIA 1 é de 14%.

Gu et al. [53] utilizaram decomposição em pirâmide para decompor uma imagem da íris em um conjunto de sub-bandas. Em seguida, é aplicado um estimador de dimensão fractal em cada sub-banda da imagem, obtendo-se um conjunto de características faixa-a-faixa que medem a auto-similaridade em uma base. Hosseini et al. [54] utilizaram uma técnica de análise de formas. Formas de exemplo detectadas na íris são representadas utilizando funções de raio-vetor e funções de apoio.

4.4.2 Análise e representação da correspondência entre códigos de íris

Analizando especificamente o processo de comparação, uma série de artigos mostraram que o desempenho pode ser melhorado usando múltiplas imagens da mesma íris. Du [55] realizou experimentos utilizando uma, duas e três imagens inscritas de uma determinada íris. As taxas de reconhecimento resultantes foram de 98,5%, 99,5% e 99,8% respectivamente.

Liu e Xie [56] apresentaram um algoritmo que utiliza a análise discriminante linear direta (DLDA). Ao testar o seu algoritmo em 1.200 imagens do conjunto de dados CASIA 2, eles mostraram que o desempenho do reconhecimento aumenta dramaticamente se aumentar de duas amostras de treinamento para quatro amostras de treinamento, e, em seguida, de forma incremental de 4 para 8.

Ma et al. [49] sugeriram analisar várias imagens inscritas e manter a de melhor qualidade. Em outro trabalho os mesmos autores utilizaram um vetor de características formado pela média de três modelos da mesma classe. Krichen et al. [57] sugeriram o valor mínimo

ao invés do valor médio para formar o vetor de características baseado nos três modelos, pois geralmente pode ocorrer erros atípicos na formação de algum modelo.

Hollingsworth et al. [10] utilizaram vários códigos do mesmo olho para avaliar quais bits são os bits mais consistentes no código íris. Eles sugeriram mascarar os bits inconsistentes no código da íris para melhorar o desempenho. Roy e Bhattacharya [58] utilizaram seis imagens de cada íris para treinar um classificador baseado em máquina de vetores de suporte (SVM).

Alguns trabalhos recomendaram que parte da íris, como por exemplo a região mais próxima da pupila, pode ser mais útil do que a região mais externa, próxima à esclera. Sanchez-Reillo e Sanchez-Avila [59] dividiram a íris em quatro partes (superior, inferior, esquerda e direita) e as porções superior e inferior são desconsideradas devido à possível oclusão.

Ma et al. [60] escolheram uma parte diferente da íris. Eles usaram três quartos da região da íris mais próximo da pupila. Pereira et al. [18] não utilizaram uma seleção uniforme dos pixels da íris. Eles dividiram a íris em 10 regiões anulares e um algoritmo genético seleciona os pontos que resulta na maior decidibilidade.

Outros trabalhos acrescentaram etapas ao processo de reconhecimento que são capazes de selecionar um subconjunto mais adequado de imagens inscritas no sistema. Qui et al. [61] dividiram as imagens em categorias com base em características visuais. Eles usaram um algoritmo K-means para determinar qual categoria uma íris pertence e obtiveram uma taxa de classificação correta de 95% em suas cinco categorias.

Yu et al. [62] calcularam a dimensão fractal de uma zona superior e de uma zona inferior da imagem da íris e utilizaram dois limiares para classificar a íris em uma das quatro categorias. Usando um pequeno número de regras de classificação, eles obtiveram uma classificação correta em 98% usando 872 imagens de 436 íris.

Ainda existem vários autores que contribuíram para o desenvolvimento de uma teoria da tomada de decisões no contexto de códigos binários. Daugman e Downing [63] descreveram um experimento para determinar a variabilidade estatística dos padrões da íris. Seu experimento avalia 2,3 milhões de comparações entre diferentes pares de íris. A distância

média de Hamming entre duas íris diferentes é 0,499, com um desvio padrão de 0,032. Esta distribuição segue de perto uma distribuição binomial com 244 graus de liberdade.

Bolle et al. [64] consideraram a probabilidade dos valores de bits em um código de íris e a distância de Hamming entre os códigos da íris para desenvolver um modelo analítico de falsa taxa de rejeição (FRR) e falsa taxa de aceitação (FAR), em função da probabilidade p de um bit inverter seu valor devido ao ruído. O modelo prevê que desempenho da FAR é relativamente estável e não é afetado por p e que o desempenho da FRR degrada rapidamente quando a taxa de inversão do bit, ou seja p , aumenta. Eles também indicaram que o desempenho FAR previsto pelo modelo é excelente de acordo com os números empíricos relatados por Daugman.

4.5 Implementação

As linhas da imagem normalizada correspondem à direção angular, ou seja, aos anéis circulares na região da íris. Devido à maior independência das características ocorrer nesta direção a extração das características é realizada pela convolução de cada linha com o filtro Log-Gabor 1D.

Os pixels das regiões de ruído, detectados na etapa de segmentação, são substituídos pelo valor médio da intensidade de tom de cinza dos outros pixels para evitar que eles interfiram na filtragem.

A informação de fase contida na saída do filtro é quantizada em quatro níveis de acordo com o quadrante do plano complexo, como mostra a Figura 4.1. Foi mostrado por Oppenheim and Lim [65] que as informações de fase são melhores do que as de amplitude para fornecer as informações mais significativas de uma imagem, uma vez que na codificação são desconsideradas as informações irrelevantes como a iluminação, que é representada pela amplitude.

Quando utilizado apenas um filtro, a quantidade de bits de uma *template* é a resolução angular multiplicada pela resolução radial multiplicada por dois bits. O processo de codi-

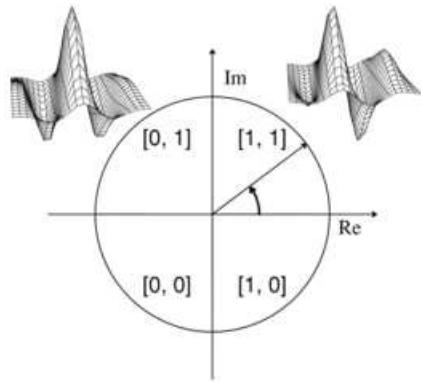


Figura 4.1: Níveis de quantização de acordo com o quadrante do plano complexo.

ficação gera, além da *template* contendo os bits de informações da íris, uma máscara de ruído correspondente que representa as áreas corrompidas. Essa máscara é gerada a partir daquela fornecida na fase de normalização e possui a mesma dimensão do *template*.

Para processar a comparação entre duas *templates* foi utilizada a distância de Hamming apresentada na Equação (4.4) e foi incluída as informações da máscara de ruído gerada na fase de codificação, de forma que somente os bits significativos sejam utilizados, ou seja, somente os bits que realmente pertencem à região da íris são utilizados para o cálculo da HD. Assim, a distância de Hamming deve ser modificada como mostrado na Equação (4.5).

$$HD = \frac{1}{N - \sum_{k=1}^N Xn_k \cup Yn_k} \sum_{j=1}^N X_j \oplus Y_j \cap Xn'_j \cap Yn'_j \quad (4.5)$$

em que: X_j e Y_j são os bits das *templates* a serem comparadas; Xn'_j e Yn'_j são o complemento de Xn_j e Yn_j , respectivamente e N é o numero total de bits de cada *template*.

Segundo Daugman, a única inconsistência entre os códigos gerados é o desalinhamento causado por variações rotacionais no momento da aquisição da imagem e, conforme citado anteriormente, a etapa de comparação pode minimizar este efeito. A Figura 4.2 ilustra o método adotado.

Depois que é calculada a DH entre duas *templates*, uma das *templates* é deslocada para a esquerda ou para a direita. Este deslocamento na direção horizontal corresponde a uma rotação da região original da íris de um ângulo devido à resolução angular usada

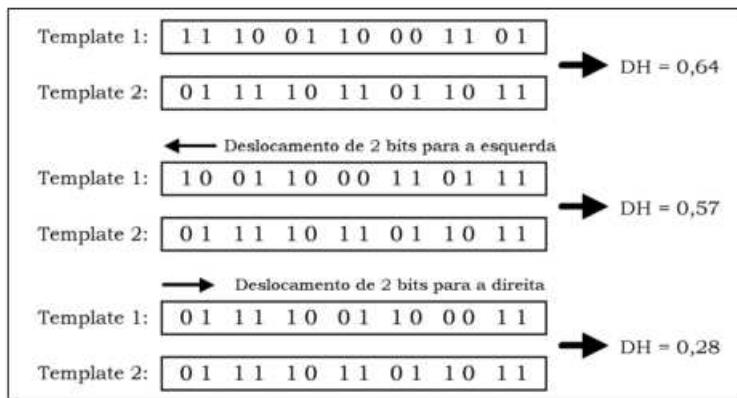


Figura 4.2: Cálculo da DH para templates deslocados.

na normalização. Durante cada deslocamento são movidos dois bits da *template*, uma vez que o processo de codificação gera dois bits de informação para cada pixel da região normalizada da íris. A cada deslocamento, as *templates* são comparados e é calculado o correspondente valor de DH.

Ao final de sucessivos deslocamentos, é escolhido o menor valor de DH que corresponde ao melhor casamento entre as *templates*. O número de deslocamentos requeridos devido as inconsistências rotacionais é determinado pela diferença angular máxima entre duas imagens da mesma íris. Um deslocamento é definido por um deslocamento para a esquerda e, em seguida, um deslocamento para a direita a partir da posição inicial.

4.6 Resultados

Não foi possível utilizar todas as imagens de cada conjunto devido à taxa de segmentação não ser perfeita. Portanto, na etapa de comparação, apenas parte das imagens dos bancos CASIA-IrisV1 e CASIA-IRIS-Lamp foram usadas para testar o sistema. A Tabela 4.1 resume a quantidade de imagens utilizadas em cada conjunto e a quantidade de comparações intraclasse e interclasse geradas a partir de cada subconjunto.

A Figura 4.3 mostra uma representação normalizada da íris e uma máscara de ruídos, ambas adquiridas na etapa de normalização, com dimensões de 20×240 pixels. A Figura

Tabela 4.1: *Imagens utilizadas para realizar testes com sistema.*

Conjunto	Imagens utilizadas	Intraclasse	Interclasse
CASIA-IrisV1	608	1.536	183.760
CASIA-IRIS-Lamp	1.753	28.608	1.521.324

4.3 também mostra uma *template* binária e uma máscara com dimensões de 20×480 pixels, geradas à partir da codificação dos pixels da representação normalizada. Nessa codificação cada pixel foi codificado usando dois bits.

Figura 4.3: *Template binária e a máscara de ruídos gerados a partir de uma imagem normalizada da íris.*

As Figuras 4.4 e 4.5 mostram o efeito do deslocamento horizontal das *templates* para obter a menor distância de Hamming. Como mencionado anteriormente, este deslocamento na direção horizontal corresponde a uma rotação da região original da íris e é necessário para tratar as inconsistências rotacionais determinadas pela diferença angular entre duas imagens da mesma íris.

A cada deslocamento, as *templates* são comparadas e é calculado o valor de DH. A Figura 4.4 mostra a distribuição com a menor distância de Hamming encontrada com 8 deslocamentos para esquerda e para a direita, enquanto que a Figura 4.5 mostra a distribuição das distâncias de Hamming sem deslocamentos.

Nesse caso, observa-se que as distribuições sem deslocamento de bits, ou seja, sem

o alinhamento rotacional, são mais espalhadas, indicando que o desempenho do sistema pode ser comprometido, pois a sobreposição intraclasse e interclasse aumenta. Quantitativamente essa sobreposição pode ser medida usando a decidibilidade. Quanto maior for a decidibilidade maior é a capacidade do sistema em decidir qual classe pertence cada amostra do conjunto. A decidibilidade será definida no Capítulo 5.

Para o conjunto CASIA-IrisV1, a decidibilidade sem deslocamento de bits tem uma degradação de 5,19 para 4,56, ou 12,18%. No conjunto CASIA-IRIS-Lamp a degradação é de 4,76 para 3,90, ou 18,06%. Observa-se também que independente do alinhamento as distribuições para o conjunto CASIA-IRIS-Lamp apresentam pior decidibilidade comparadas com o conjunto CASIA-IrisV1.

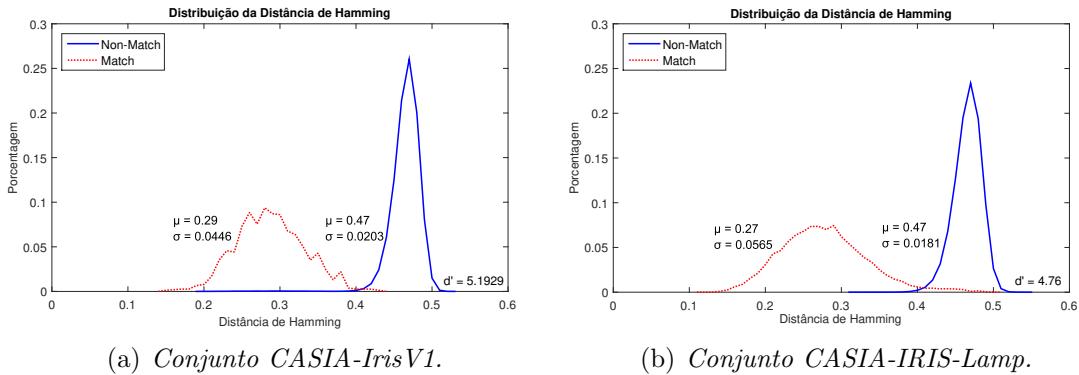


Figura 4.4: *Distribuição das distâncias de Hamming com deslocamento de bits para as imagens utilizadas. Melhor distribuição encontrada com até 8 deslocamentos.*

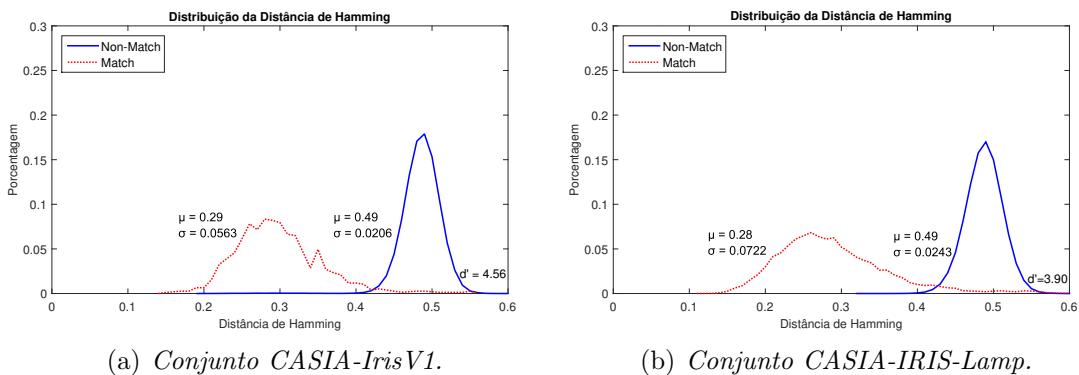


Figura 4.5: *Distribuição das distâncias de Hamming sem deslocamento de bits para as imagens utilizadas.*

Desempenho do Sistema

5.1 Introdução

O principal objetivo de um sistema de reconhecimento de íris é ser capaz de obter uma boa separação entre as distribuições geradas a partir de comparações intraclasse e interclasse. O sistema é mais confiável quanto mais separados os dois casos estiverem, uma vez que a sobreposição entre as distribuições originam taxas de erro.

A Figura 5.1 mostra um exemplo de ambiente de decisão onde as distribuições são separadas pela distância de Hamming. O critério de decisão é baseado no limiar S e sua movimentação pode definir estratégias diferentes dependendo do tipo de erro tolerável em uma determinada aplicação.

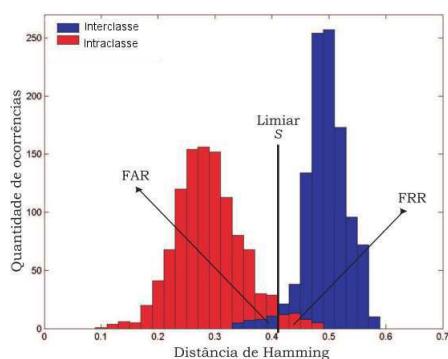


Figura 5.1: Representação das distribuições intraclasse e interclasse - Ambiente de decisão.

Um parâmetro chamado decidibilidade [1] mede a separação entre as distribuições, independente do limiar adotado para decisão, levando em consideração a média e o desvio padrão de cada uma. Sendo μ_1 e μ_2 as médias e σ_1 e σ_2 os desvios padrões das duas distribuições, a decidibilidade é obtida pela Equação (5.1).

$$d' = \frac{|\mu_1 - \mu_2|}{\sqrt{(\sigma_1^2 + \sigma_2^2)/2}} \quad (5.1)$$

A performance de qualquer sistema de biometria pode ser ajustada pelo seu valor de decidibilidade. Quanto maior a decidibilidade, maior a separação entre as distribuições intraclasse e interclasse e, consequentemente, maior a precisão no reconhecimento.

O software implementado fornece a distribuição dos códigos correspondentes (match) e dos códigos não correspondentes (non-match), ou seja, ele determina o histograma das distâncias de Hamming intraclasse e interclasse, conforme mostra a Figura 5.2.

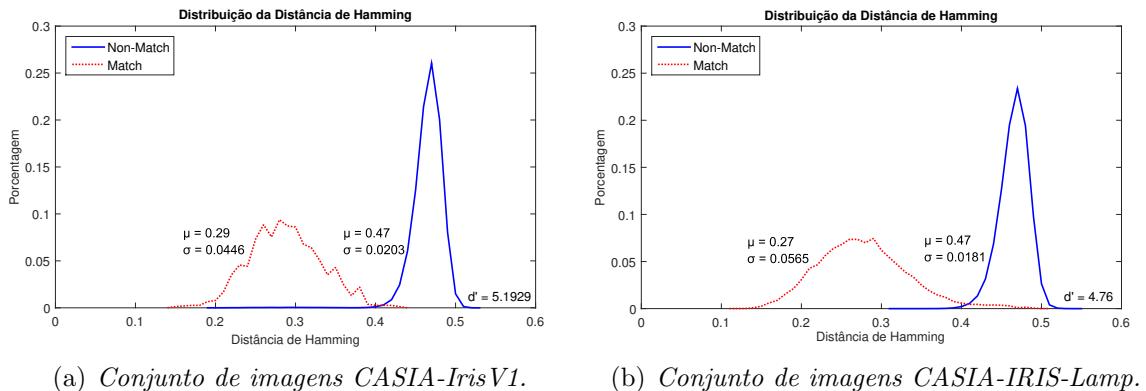


Figura 5.2: Distribuição das distâncias de Hamming para os conjuntos de imagens CASIA-IrisV1 e CASIA-IRIS-Lamp.

Pode-se observar claramente na Figura 5.2 que existe sobreposição de valores entre as duas distribuições para os dois conjuntos de imagens. Normalmente, nesse caso a sobreposição representa a taxa de erro do sistema que necessariamente deverá escolher um valor de distância de Hamming para ser o limiar e garantir que a probabilidade de uma falsa correspondência fique abaixo de um nível especificado.

A proporção esperada de bits concordantes entre os códigos de duas iris diferentes é de

50%, o que corresponde a uma distância de Hamming igual a 0,5 [1]. Contudo, pode-se reduzir este valor para $HD = 0,45$ devido à correção no alinhamento dos códigos [16]. No trabalho de Daugman [1], a média das distâncias de Hamming para a distribuição *match* foi de 0,110 e a média das distâncias de Hamming para a distribuição *non-match* foi de 0,458, resultando em uma decidibilidade de 7,3. Além disso, Daugman utilizou um limiar adaptativo, variando de 0,27 a 0,33, para separar as distribuições *match* e *non-match*.

A média da distribuição *match* do conjunto Casia-IrisV1 na Figura 5.2 é de 0,29. Além disso, 100% destas amostras possuem HD menor do que o limiar de 0,45 (nenhum falso negativo). Por sua vez, a média da distribuição *non-match* é de 0,47 e 19,24% destas amostras possuem HD menor do que o limiar de 0,45 (falso positivo). Aqui a decidibilidade foi de 5,19.

Para o conjunto Casia-IRIS-Lamp a média da distribuição *match* na Figura 5.2 é de 0,27. Além disso, 1,60% destas amostras possuem HD maior ou igual ao limiar de 0,45 (falso negativo). Por sua vez, a média da distribuição *non-match* é de 0,47 e 20,98% destas amostras possuem HD menor do que o limiar de 0,45 (falso positivo). Aqui a decidibilidade foi de 4,76, que corresponde a uma degradação de aproximadamente 8% em relação ao conjunto Casia-IrisV1.

A Figura 5.2 também mostra que o melhor limiar para separar as distribuições *match* e *non-match* é de 0,40 para os dois conjuntos de imagens. Conforme citado anteriormente, esse valor influencia o erro do sistema e pode variar dependendo da estratégia adotada para a aplicação.

5.2 Resultados Experimentais

Para verificar a influência do movimento de contração e dilatação da íris no processo de reconhecimento biométrico, três experimentos foram realizados. Os resultados serão avaliados utilizando a decidibilidade, a matriz de confusão, mostrada na Tabela 5.1, e ainda as curvas *receiver operating characteristic* (ROC), no cenário de verificação e a curva

Tabela 5.1: *Matriz de confusão utilizada para mostrar o desempenho do sistema.*

True positive - TP	False positive - FP	Positive predictive value $\frac{TP}{TP+FP}$
False negative - FN	True negative - TN	Negative predictive value $\frac{TN}{FN+TN}$
Sensitivity $\frac{TP}{TP+FN}$	Specificity $\frac{TN}{FP+TN}$	Accuracy $\frac{TP+TN}{TP+FN+FP+TN}$

cumulative match characteristic (CMC), no cenário de identificação.

Considerando o cenário de identificação, uma amostra biométrica é adquirida sem qualquer declaração de identidade associada. A tarefa é identificar a amostra desconhecida como sendo correspondente a uma amostra inscrita e previamente conhecida no banco de dados. O conjunto de amostras inscritas é frequentemente chamado de *galeria* e a amostra desconhecida é muitas vezes denominada de *prova*.

A prova é comparada com todas as entradas da galeria. Caso o sistema encontre imagens afins, a correspondência mais próxima é usada para identificar a amostra desconhecida. O desempenho em um cenário de identificação é frequentemente resumido em uma curva *cumulative match characteristic* (CMC) onde a pontuação de similaridade para cada comparação é colocada em ordem crescente.

O processo de identificação pode obter quatro possíveis resultados. Um verdadeiro positivo (TP) ocorre quando o sistema determina que uma amostra desconhecida corresponde a uma pessoa em particular na galeria e a correspondência está correta. Um falso positivo (FP) ocorre quando o sistema determina que uma amostra desconhecida corresponde a uma pessoa em particular na galeria e a correspondência não é correta. Um verdadeiro negativo (TN) ocorre quando o sistema determina que a amostra não corresponde a qualquer das entradas pertencentes à galeria e a amostra verdadeiramente não pertence. Um falso negativo (FN) ocorre quando o sistema determina que a amostra não corresponde a qualquer das entradas na galeria, mas a amostra de fato pertence a alguém na galeria.

No cenário de verificação, o sistema é utilizado para verificar ou rejeitar uma identidade particular com base na validação de uma amostra coletada contra uma amostra biométrica do indivíduo previamente inscrita. Da mesma forma, o processo de verificação pode obter quatro resultados possíveis. Um verdadeiro positivo (TP) ocorre quando o sistema aceita,

ou verifica, uma declaração de identidade, e a afirmação é verdadeira. Um falso positivo (FP) ocorre quando o sistema aceita uma declaração de identidade, mas a alegação não é verdadeira. Um verdadeiro negativo (TN) ocorre quando o sistema rejeita uma declaração de identidade e a verificação realmente é falsa. Um falso negativo (FN) ocorre quando o sistema rejeita uma declaração de identidade, mas a verificação é verdadeira. Os dois tipos de erros que podem ocorrer são um falso aceite e uma falsa rejeição.

O desempenho do sistema de biometria em um cenário de verificação é frequentemente resumido em uma curva *receiver operating characteristic* (ROC) construída em termos de três taxas de erros. A taxa de falsa rejeição (FRR), representada no eixo Y da ROC, indica a probabilidade do indivíduo apto ser considerado impostor e, portanto, ser recusado pelo sistema. A taxa de falsa aceitação (FAR), mostrada no eixo X da ROC, indica a probabilidade de um impostor ser aceito pelo sistema.

A taxa de erro igual (EER), único número frequentemente citado a partir da curva ROC, representa o valor onde a FRR é igual à FAR. Quanto menor for a EER maior será a capacidade do sistema classificar corretamente uma amostra.

5.2.1 Experimento 1

Para este experimento foi considerado o cenário de identificação e de verificação para as imagens do conjunto CASIA-IrisV1 e CASIA-IRIS-Lamp. Os resultados são mostrados na matriz de confusão para cada conjunto utilizado, de acordo com a Tabela 5.2, e pelas curvas CMC e ROC.

Além dos resultados de falso positivo (FP), falso negativo (FN), verdadeiro positivo (TP) e verdadeiro negativo (TN) a matriz de confusão informa a sensibilidade, a especificidade, a precisão, o valor preditivo positivo e o valor preditivo negativo.

A sensibilidade (S_t) mede a proporção de verdadeiro positivo que é corretamente identificada pelo sistema, ou seja, a proporção de correspondência correta encontrada pelo sistema. A especificidade (S_f) mede a proporção de verdadeiro negativo que é corretamente identificado pelo sistema, ou seja, a proporção de não correspondência correta encontrada

pelo sistema. A precisão (A) indica a proporção de predições corretas realizada pelo sistema, sem levar em conta o que é positivo e o que é negativo. Uma precisão de 100% indica que o sistema classificou corretamente todas as amostras utilizadas no teste.

O valor preditivo positivo (P_p) e o valor preditivo negativo (P_n) representam a proporção de verdadeiros positivos em relação a todas as predições positivas e a proporção de verdadeiros negativos em relação a todas as predições negativas, respectivamente.

Tabela 5.2: *Matriz de confusão do melhor resultado - Threshold = 0,40.*

(a) CASIA-IrisV1			(b) CASIA-IRIS-Lamp		
$TP = 437,96$	$FP = 379,57$	$P_p = 0,45$	$TP = 7.712,4$	$FP = 13.941,00$	$P_p = 0,35$
$FN = 5,78$	$TN = 85.162,00$	$P_n = 0,99$	$FN = 275,46$	$TN = 703.380,00$	$P_n = 0,99$
$S_t = 0,98$	$S_f = 0,99$	$A = 0,99$	$S_t = 0,96$	$S_f = 0,98$	$A = 0,98$

As curvas CMC das Figuras 5.3 apresentam as taxas de reconhecimento *rank-one*, ou seja, mostram o desempenho do sistema para as melhores correspondências entre as imagens de teste e da galeria. A taxa inicial de reconhecimento é bem próxima para os dois conjuntos, contudo para outras posições do rank o conjunto CASIA-IrisV1 apresenta taxas de reconhecimento maiores que o conjunto CASIA-IRIS-Lamp.

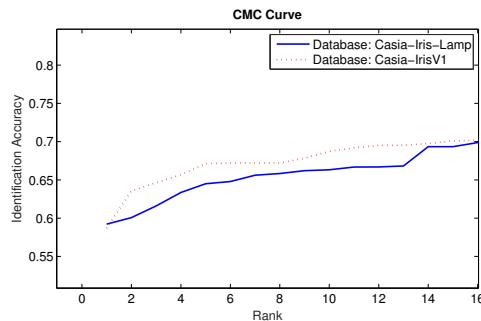


Figura 5.3: *Cumulative Match Characteristic para CASIA-IrisV1 e CASIA-IRIS-Lamp.*

As curvas ROC da Figura 5.4 determinam as taxas de erro igual (EER) para os conjuntos de imagens utilizados. Para o conjunto CASIA-IrisV1 a EER foi de 0,75% e para o conjunto CASIA-IRIS-Lamp a EER foi de 2,16%. Isso representa uma degradação de 288%.

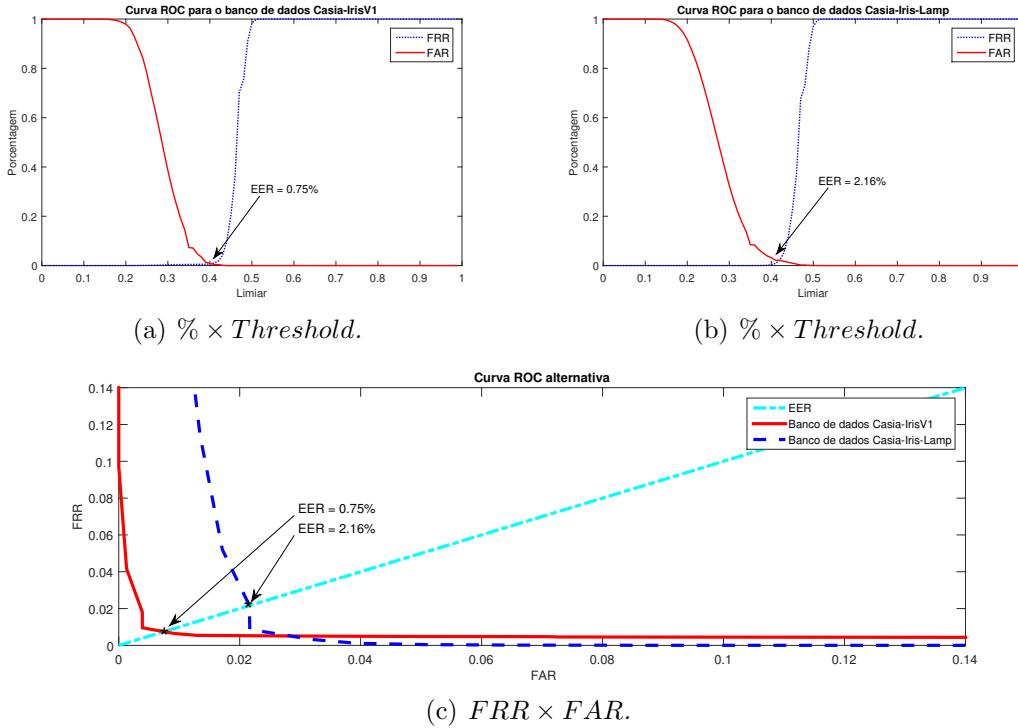


Figura 5.4: *Receiver Operating Characteristic* para CASIA-IrisV1 e CASIA-IRIS-Lamp.

5.2.2 Experimento 2

Para este experimento foi utilizado apenas o conjunto CASIA-IRIS-Lamp, contudo as imagens deste conjunto foram divididas em três grupos de acordo com a taxa de dilatação da pupila. Durante a segmentação, a transformada de Hough fornece o raio da pupila e o raio da íris. Para determinar a taxa de dilatação o raio da pupila foi dividido pelo raio da íris. Dessa forma, como o raio da pupila é sempre menor do que o raio da íris, a relação de dilatação deve ser sempre um número entre 0 e 1. Para todas as 1.753 imagens do conjunto CASIA-IRIS-Lamp utilizadas, a taxa de dilatação ficou entre 0,20 e 0,70.

A Figura 5.5 mostra a distribuição das imagens do conjunto CASIA-IRIS-Lamp de acordo com a taxa de dilatação. Dessa forma, o primeiro subconjunto, denominado de Subconjunto (1), consiste das imagens com pupilas menores ou com pupilas contraídas, onde as taxas de dilatação são menores do que 0,36. O segundo subconjunto, denominado de Subconjunto (2), compreende as imagens com pupilas de tamanho intermediário, com

taxas de dilatação entre 0,36 e 0,52. O terceiro subconjunto, denominado de Subconjunto (3), contém as imagens com pupilas maiores ou dilatadas, onde as taxas de dilatação são maiores do que 0,52.

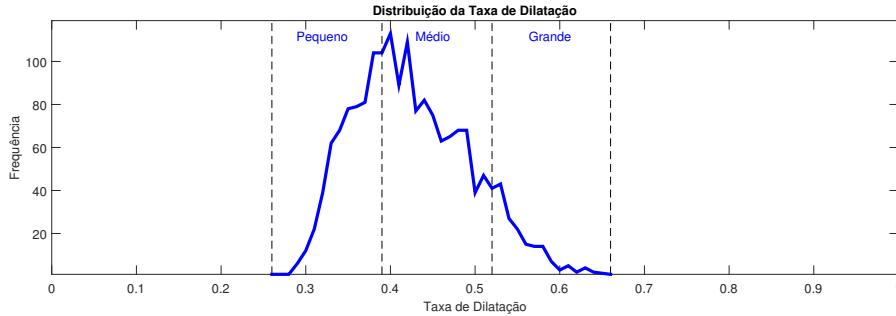


Figura 5.5: *Distribuição da taxa de dilatação. Raio da pupila dividido pelo raio da íris.*

A Figura 5.6 mostra a distribuição das distâncias de Hamming para cada um dos subconjuntos. Para o Subconjunto (1) a média das distribuições correspondentes foi de 0,26, com desvio padrão de 0,0512. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,47, com desvio padrão de 0,0161 e a decidibilidade encontrada foi 5,53.

Para o Subconjunto (2) a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0562. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,47, com desvio padrão de 0,0185 e a decidibilidade encontrada foi 4,78.

Para o Subconjunto (3) a média das distribuições correspondentes foi de 0,25, com desvio padrão de 0,0519. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0228 e a decidibilidade encontrada foi 5,24.

As matrizes de confusão para cada subconjunto são mostradas na Tabela 5.3. O sistema apresenta uma precisão de 99% para o Subconjunto (1), onde a taxa de dilatação é a menor. O Subconjunto (2) possui o maior número de imagens e a pior sensibilidade, cerca de 96%, ou seja, a pior proporção de verdadeiro positivo.

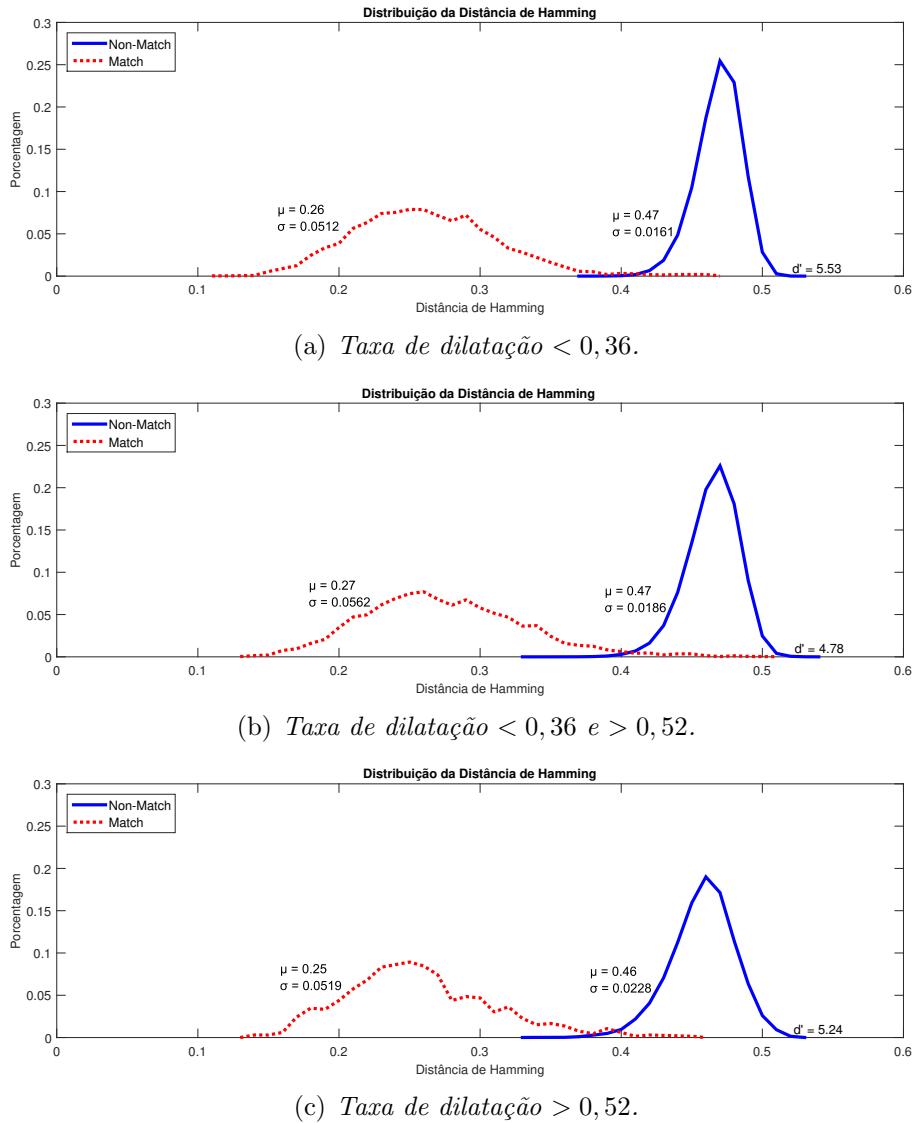


Figura 5.6: Distribuição das distâncias de Hamming de acordo com a taxa de dilatação.

É importante ressaltar que os valores das matrizes de confusão são obtidos em função do limiar adotado. Além disso, o limiar pode variar de acordo com a distribuição das distâncias de Hamming e, conforme descrito na seção 4.5, o alinhamento dos códigos interfere diretamente nesse valor.

As curvas ROC da Figura 5.7 determinam as EER para os três subconjuntos. Para os Subconjuntos (1), (2) e (3) as EER foram de 0,98, 1,76 e 1,55, respectivamente.

Tabela 5.3: Matriz de confusão do melhor resultado para cada subconjunto.

(a) Imagens com menor taxa de dilatação.			(b) Imagens com taxa de dilatação intermediária.		
$TP = 1.913,3$	$FP = 793,46$	$P_p = 0,71$	$TP = 3.021,9$	$FP = 1.950,40$	$P_p = 0,61$
$FN = 30,02$	$TN = 99.417,00$	$P_n = 0,99$	$FN = 108,22$	$TN = 199.920,00$	$P_n = 0,99$
$S_t = 0,98$	$S_f = 0,99$	$A = 0,99$	$S_t = 0,96$	$S_f = 0,99$	$A = 0,98$
(c) Imagens com maior taxa de dilatação.					
$TP = 336,30$	$FP = 87,67$	$P_p = 0,79$			
$FN = 6,6$	$TN = 5.402,8$	$P_n = 0,99$			
$S_t = 0,98$	$S_f = 0,98$	$A = 0,98$			

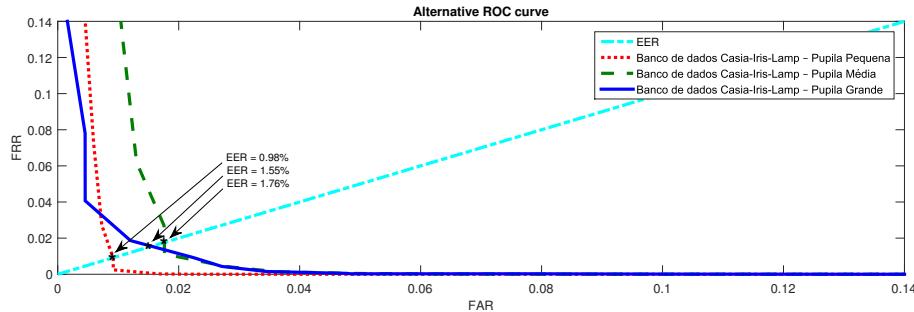


Figura 5.7: ROC para os três intervalos de taxa de dilatação.

5.2.3 Experimento 3

Neste experimento as imagens comparadas, obrigatoriamente, pertencem à subconjuntos diferentes. Nesse caso, as distribuições das distâncias de Hamming referem-se às comparações entre as imagens com taxas de dilatação bem diferentes. A Tabela 5.4 mostra, de forma simplificada, as comparações realizadas neste experimento.

Tabela 5.4: Experimento 3. Verificação entre imagens de subconjuntos diferentes.

Amostra coletada		Amostra inscrita
Subconjunto (1) (Taxa de dilatação < 0,36)	X	Subconjunto (3) (Taxa de dilatação > 0,52)
Subconjunto (1) (Taxa de dilatação < 0,36)	X	Subconjunto (2) (0,36 < Taxa de dilatação < 0,52)
Subconjunto (2) (0,36 < Taxa de dilatação < 0,52)	X	Subconjunto (3) (Taxa de dilatação > 0,52)

A Figura 5.8 mostra a distribuição das distâncias de Hamming para as comparações entre os subconjuntos. A Figura 5.8a mostra a distribuição das distâncias de Hamming para os Subconjuntos (1) e (2) onde a média das distribuições correspondentes foi de 0,29 com desvio padrão de 0,0547. Para as distribuições não correspondentes a média foi de 0,47 com desvio padrão de 0,0173. A decidibilidade encontrada foi 4,44.

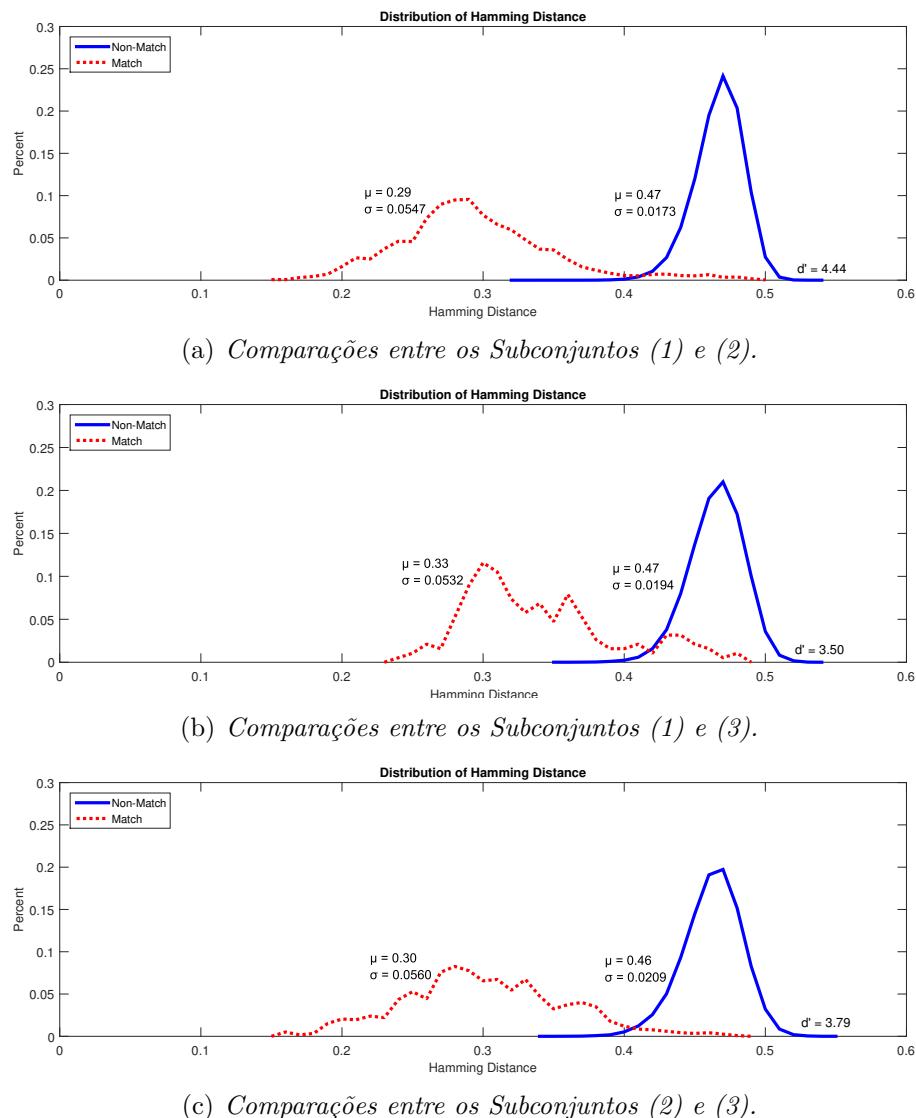


Figura 5.8: Distribuição das distâncias de Hamming entre os Subconjuntos (1 e 2), (1 e 3) e (2 e 3).

A Figura 5.8b mostra a distribuição das distâncias de Hamming para os Subconjuntos

(1) e (3), onde a média das distribuições correspondentes foi de 0,33, com desvio padrão de 0,0532 e para as distribuições não correspondentes a média foi de 0,47, com desvio padrão de 0,0194. A decidibilidade encontrada foi de 3,50.

A Figura 5.8c mostra a distribuição das distâncias de Hamming para os Subconjuntos (2) e (3), onde a média das distribuições correspondentes foi de 0,30, com desvio padrão de 0,0560. Para as distribuições não correspondentes a média foi de 0,46, com desvio padrão de 0,0209. A decidibilidade encontrada foi 3,79.

As matrizes de confusão para as comparações entre os subconjuntos são mostradas na Tabela 5.5. Para a verificação entre os Subconjuntos (1) e (3) o sistema apresenta uma precisão de 97%. Para a verificação entre os Subconjuntos (1) e (2) o sistema apresenta uma precisão de 99%. Para a verificação entre os Subconjuntos (2) e (3) o sistema apresenta uma precisão de 98%.

Tabela 5.5: *Matriz de confusão do melhor resultado para comparação entre subconjuntos.*

(a) Distribuição das distâncias de Hamming entre os Subconjuntos (1) e (2). (b) Distribuição das distâncias de Hamming entre os Subconjuntos (1) e (3).

$TP = 802,25$	$FP = 754,86$	$P_p = 0,51$	$TP = 54,65$	$FP = 639,67$	$P_p = 0,078$
$FN = 59,04$	$TN = 155.240,00$	$P_n = 0,99$	$FN = 10,67$	$TN = 27.974,00$	$P_n = 0,99$
$S_t = 0,93$	$S_f = 0,99$	$A = 0,99$	$S_t = 0,83$	$S_f = 0,97$	$A = 0,97$

(c) Distribuição das distâncias de Hamming entre os Subconjuntos (2) e (3).

$TP = 339,30$	$FP = 679,91$	$P_p = 0,33$
$FN = 17,67$	$TN = 37.884,00$	$P_n = 0,99$
$S_t = 0,95$	$S_f = 0,98$	$A = 0,98$

As curvas ROC da Figuras 5.9 determinam as EER para a comparação entre os três subconjuntos. Para a comparação entre os Subconjuntos (1 e 3), (1 e 2) e (2 e 3) as EER foram de 9,69%, 3,52% e 2,64%, respectivamente. Para uma rápida comparação, a Figura 5.9 também mostra a EER de 2,16%, referente à verificação utilizando todas as imagens. Lembrando que quanto menor for a EER maior será a capacidade do sistema em classificar corretamente uma amostra.

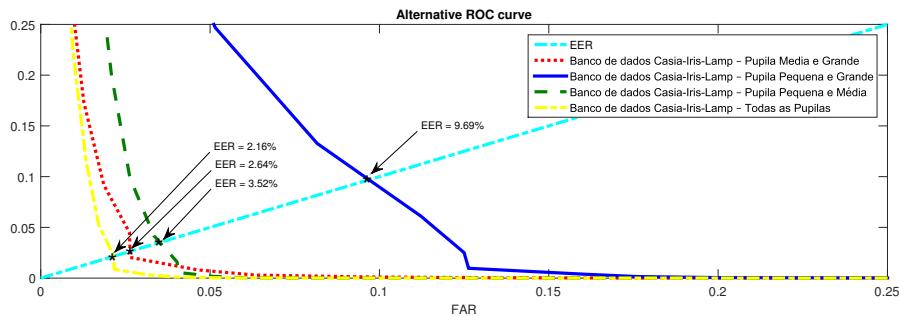


Figura 5.9: *ROC para a comparação entre os subconjuntos.*

5.3 Discussão

Os resultados experimentais mostraram que a resposta do sistema é bastante influenciada quando são utilizadas imagens com maior variabilidade intraclasse, ou seja, imagens com diferentes taxas de dilatação. Dessa forma, os experimentos sugerem, de forma notória, que o conjunto CASIA-IRIS-Lamp está mais sujeito a erros por apresentar maior variabilidade devido ao movimento do tecido da íris.

Existem claros indícios que o espaçamento temporal entre as imagens a serem comparadas deve ser levado em conta e que, ao contrário do que Daugman [14] afirmou, o modelo *homogeneous rubber sheet* não é capaz de eliminar os problemas causados pela contração e dilatação do tecido da íris.

No primeiro experimento ficou evidente que a variação no tamanho da íris causou variações nas taxas de erro falso positivo e falso negativo. Esse fato pode ser evidenciado pela decidibilidade, que é menor para o conjunto CASIA-IRIS-Lamp quando comparada com a decidibilidade do conjunto CASIA-IrisV1 e pela EER.

As EER, mostradas nas curvas ROC do primeiro experimento, também indicaram a maior dificuldade do sistema em classificar corretamente as amostras. Para os conjuntos CASIA-IrisV1 e CASIA-IRIS-Lamp as EER foram 0,76 e 2,16, respectivamente. Esse resultado mostrou de forma significativa a degradação do sistema quando as imagens apresentam maior variabilidade.

A precisão e a especificidade foram de 99% para o conjunto CASIA-IrisV1. Para o conjunto CASIA-IRIS-Lamp a precisão e a especificidade foram de 98%. A sensibilidade para o conjunto CASIA-IrisV1 foi 98% e para o conjunto CASIA-IRIS-Lamp foi de 96%. De forma geral, a comparação entre os resultados das matrizes mostrados na Tabela 5.2 indicam o melhor desempenho do sistema para o conjunto de imagens CASIA-IrisV1.

A curva CMC *rank-one*, também do primeiro experimento, mostrou que no processo de identificação o sistema é mais preciso para o conjunto CASIA-IrisV1, pois sua taxa de identificação para a mesma posição do rank é em média 6% maior do que a do conjunto CASIA-IRIS-Lamp.

No segundo experimento, existe uma clara indicação que, para imagens com a taxa de dilatação intermediária, entre 0,36 e 0,52, a decidibilidade diminui, deteriorando a resposta do sistema. Para imagens com taxa de dilatação menor do que 0,36 e maior do que 0,52 as decidibilidades se aproximam. Para o primeiro caso a decidibilidade é de 5,53 e para o segundo caso a decidibilidade é de 5,25, uma diferença de apenas 5%. Esse fato evidencia a influência da variação no tamanho da íris no desempenho do sistema de reconhecimento.

Uma possível justificativa para o resultado acima pode ser encontrada no fato de que imagens com baixa taxa de dilatação possuem íris com área maior e portanto, os pontos amostrados para formar a *template* possuem características mais discriminantes, pois estão mais afastados entre si. Pelo mesmo raciocínio, imagens com maior taxa de dilatação possuem menor área de íris, porém as estruturas da íris estão mais comprimidas formando uma textura com grande quantidade de bordas e cantos que representam características mais discriminantes.

Por outro lado, imagens com taxa de dilatação intermediária apresentam uma textura com baixa frequência e poucas características devido ao menor espaçamento entre os pontos amostrados. Dessa forma, os códigos da íris gerados a partir dessas imagens apresentam poucos bits significativos, aumentando a intersecção das distribuições match e non-match no ambiente de decisão e diminuindo a decidibilidade.

De forma clara, as curvas ROC dos três conjuntos que foram separados pela taxa de dilatação, seguem a mesma tendência das distribuições de HD. Como citado anteriormente,

quanto menor a EER maior é a capacidade do sistema em decidir corretamente a qual classe a amostra pertence.

Assim, verifica-se que o subconjunto com menor taxa de dilatação apresenta a menor EER, 0,98, enquanto o subconjunto com taxa de dilatação intermediária apresenta a maior EER, 1,76, mostrando a influência dos movimentos da íris no processo de reconhecimento.

No terceiro experimento fica mais evidente a influência da dinâmica pupilar no sistema de reconhecimento. Nas três comparações realizadas, as decidibilidades representam os piores resultados. A decidibilidade de 3,50 na comparação entre os Subconjuntos (1) e (3), que corresponde à comparação entre imagens com pupilas contraídas e pupilas dilatadas, representa o pior resultado.

A decidibilidade para a comparação entre os Subconjuntos (2) e (3) foi de 3,79 e para a comparação entre os Subconjuntos (1) e (2) foi de 4,44. As EER para o terceiro experimento seguem a mesma direção da decidibilidade. A EER de 9,69 para a comparação entre os Subconjuntos (1) e (3) representa o pior resultado, considerando todos os cenários. A EER para a comparação entre os Subconjuntos (2) e (3) foi de 2,64 e para a comparação entre os Subconjuntos (1) e (2) foi de 3,52.

Assim, pode-se comprovar que o modelo *homogeneous rubber sheet* realmente não é o mais adequado, pois a deformação da íris presente na comparação entre os Subconjuntos (1) e (3) é a máxima possível, e portanto, as características utilizadas na etapa de comparação estão desordenadas.

5.4 Conclusão

Pelos experimentos realizados foi possível caracterizar quantitativamente o efeito da movimentação do tecido da íris no desempenho do sistema de reconhecimento biométrico. As distribuição das distâncias de Hamming para as imagens com pupilas dilatadas ou comprimidas apresentaram decidibilidade maior do que as distribuições para pupilas com taxas de dilatação intermediária. Além disso, as distribuição das distâncias de Hamming para

imagens com pupilas contraídas e pupilas dilatadas apontam a influência da deformação não linear do tecido da íris.

Apesar do melhor desempenho apresentado por Daugman, o software desenvolvido neste trabalho pode ser utilizado para mostrar como a movimentação da pupila interfere na escolha do limiar. Apesar de todas as técnicas utilizadas para construir um código de íris invariante à rotação, translação e transformações afins, os resultados indicaram que alguns bits no código da íris são inconsistentes, ou seja, em uma comparação direta alguns bits são mais confiáveis do que outros, indicando que o modelo linear *homogeneous rubber sheet* realmente não é o mais adequado.

Método Proposto para a Extração das Características Permanentes da Íris

6.1 Introdução

Conforme descrito nos capítulos 2, 3 e 4 os sistemas de reconhecimento de íris alcançaram alto nível de sucesso sob condições restritas. No entanto, como comprovado no capítulo 5, ainda existem desafios quando as imagens apresentam alto grau de deformação causado pela variação de iluminação.

De forma geral, a informação da variação da íris é desconsiderada quando a imagem é normalizada [9]. Atualmente, alguns trabalhos tratam, de forma parcial, o problema associado com as variações de tamanho entre a íris cadastrada no sistema (*enrollment image*) e a imagem a ser identificada ou verificada. Porém, os trabalhos mais relevantes nesta área apenas apresentam modelos matemáticos probabilísticos, aplicados na etapa de normalização ou logo após.

Wei et. al. [15], propuseram um algorítmico de normalização não linear para corrigir a deformação da íris, onde a distância de qualquer ponto da região da íris até a borda da pupila é considerada como sendo a distância da deformação linear mais um desvio aditivo. Como modelo de desvio foi utilizado uma função Gaussiana e os seus resultados comprovaram uma redução na Taxa de Erro Igual (EER) quando comparado com os métodos de normalização lineares.

Thornton et. al. [13], estimaram a máxima probabilidade a posteriori dos parâmetros relativos à deformação causada por alguma transformação (possivelmente não linear) entre duas imagens com o objetivo de normalizar o padrão de deformação e retornar uma métrica de similaridade tolerante à esta deformação. Segundo esses autores, esse método probabilístico pode ser utilizado em qualquer tipo de padrão que experimenta deformações não lineares no plano. Seus resultados demonstraram uma significativa melhora na correspondência entre as imagens.

Ma et. al. [3] descreveram um algoritmo capaz de registrar as variações locais da estrutura da íris. O principal objetivo é que os pontos com variações locais bruscas denotem o aparecimento ou o desaparecimento de estruturas importantes da íris que podem ser utilizadas para representar suas características. Dessa forma, por meio de uma classe particular de *wavelets*, uma vetor de posições das variações bruscas na imagem normalizada é gravado como característica da íris.

6.2 Definindo o Problema

O método proposto, que será detalhado na Seção 6.3, foi motivado pelos trabalhos de Hollingsworth et. al. [10] e Monro et. al [66].

Hollingsworth et. al. [10] abordam a definição de *bits frágeis*, sugerida por Bolles [64]. Esses autores consideraram que alguns bits do código da íris têm maior probabilidade de inverterem devido ao ruído nas imagens. Desse modo, o processo de quantização dos bits próximos aos eixos de quantização pode ser altamente inconsistente, conforme mostra a Figura 6.1.

Contudo, para a identificação dos bits menos consistentes é preciso armazenar e processar várias imagens da mesma íris. Além disso, Hollingsworth et. al. [10] utilizaram imagens normalizadas e não consideraram a dinâmica da íris e, finalmente, a definição de *bits frágeis* só se aplica aos sistemas baseados na proposta de Daugman, onde os coeficientes complexos da saída do filtro de textura são transformados em um código composto

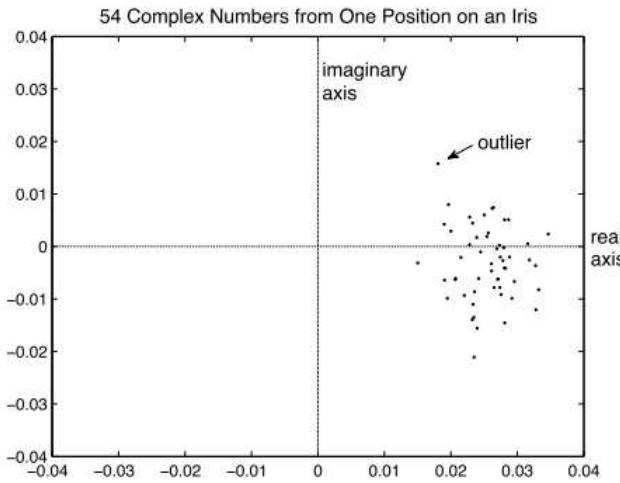


Figura 6.1: Mapeamento de 54 números complexos que representam a saída do filtro de extração de características da mesma região da íris.

por bits.

Na transformação da saída do filtro em dois bits, o primeiro bit será igual a 1 se a parte real do coeficiente for positiva e o segundo bit será igual a 1 se a parte imaginária for positiva. No exemplo da Figura 6.1, se uma região da íris for associada ao coeficiente complexo com a parte imaginária próxima a zero, então pequenos ruídos neste coeficiente podem alternar o código binário desta região de 10, em algumas situações para 11 em outras situações. Assim, é possível dizer que o bit em questão pode ser considerado um *bit frágil*, interferindo na precisão do sistema de reconhecimento.

Por sua vez, Monro et al. [66] utilizaram a transformada discreta do cosseno (DCT) para a extração de características da imagem normalizada da íris. Eles aplicaram a DCT em regiões retangulares sobrepostas. As diferenças entre os coeficientes da DCT para regiões adjacentes são então calculadas e um código binário é gerado a partir de seus cruzamentos por zero. Com a finalidade de aumentar a velocidade da correspondência, os três coeficientes mais discriminantes da DCT são mantidos e os restantes são desconsiderados.

Mais uma vez, os autores utilizaram imagens normalizadas e não consideraram a dinâmica da íris. Além disso, é necessário estimar e subtrair o nível de iluminação de cada imagem para tentar nivelar os coeficientes da DCT.

Dessa forma, considerando um ambiente mais real, espera-se um incremento na inconsistência entre os códigos gerados a partir da mesma íris, não só pela proximidade dos coeficientes complexos em relação os eixos, mas também pela dinâmica do tecido da íris. Essa hipótese é reforçada pelos experimentos realizados no capítulo 5 e pelos motivos descritos na seção 1.3 do capítulo 1 deste trabalho, resumidos nos itens a seguir:

- A pressão no tecido da íris durante seu movimento pode fazer com que algumas pequenas regiões se dobram por baixo de outras. Isso significa que pequenas partes do padrão desaparecerão e nenhum modelo de deformação será capaz de representar essa transformação [13];
- Sob forte compressão, a textura da íris produz uma imagem normalizada com muitas diferenças da imagem normalizada em condições normais [12] e [13]. Dessa forma, as regiões não influenciadas ou menos influenciadas pelos movimentos da íris devem fornecer informações suficientes para o processo de reconhecimento; e
- O modelo *homogeneous rubber sheet* não representa a verdadeira deformação do tecido da íris e, segundo Wyatt [15], um modelo não linear é mais adequado.

6.3 Método Proposto

Como citado anteriormente, a íris é formada por pequenos blocos irregulares com distribuição aleatória e constituídos por estrias, criptas, sulcos, sardas e assim por diante. Essa distribuição aleatória e o conjunto de blocos representam as características mais distintivas da íris.

Infelizmente, a posição de cada bloco e sua variação local também são aleatórias quando leva-se em consideração o deslocamento não linear do tecido da íris durante sua contração e dilatação.

Assim, para resolver o problema e alinhar corretamente as características a serem comparadas, propõe-se o uso do histograma de gradientes orientados (HoG) para descrever os

movimentos realizado pelo tecido da íris, associado ao algorítimo *Dynamic Time Warping* (DTW) para alinhar as características que sofreram deformações não lineares e calcular a similaridade entre a imagem armazenada e a imagem de teste.

A abordagem proposta baseia-se na técnica de reconhecimento parcial da íris, onde o teste de correspondência entre as imagens é feito apenas nas regiões mais similares, considerando o estado de contração e dilatação da íris. O objetivo é aumentar a decidibilidade e diminuir a EER de sistemas que utilizam imagens dinâmicas.

As duas próximas subseções descrevem as técnicas HoG e DTW. Em seguida, é mostrado a implementação da abordagem proposta, os experimentos realizados e os resultados obtidos. Posteriormente, os resultados obtidos são comparados com os resultados apresentados no capítulo 5. E, finalmente, são apresentadas as conclusões deste capítulo.

6.3.1 Histogramas de Gradientes Orientados - HoG

As características dos objetos em imagens digitais, como por exemplo a forma, a cor e a textura, podem ser mensuradas e agrupadas em um vetor de escalares, denominado descritor de imagem.

Dessa forma, cada objeto pode ser representado por um ponto em um espaço R_n , para n características. É desejável que um descritor seja invariante a transformações afins.

O algoritmo histograma de gradientes orientados (HoG), proposto por [67], é um descritor que calcula o histograma da orientação dos gradientes na imagem e é representado por um vetor de histogramas extraídos da imagem. O HoG tem como objetivo extrair informações referentes à intensidade dos gradientes ou a direção das bordas, sem um conhecimento prévio da posição de tais bordas.

Normalmente, o processo para gerar o descritor é dividido em quatro etapas: cálculo do gradiente em cada pixel, agrupamento dos pixels em células, agrupamento das células em blocos e obtenção do descritor.

Na primeira etapa, calcula-se o gradiente de cada pixel na imagem em escala de cinzas. Dada uma imagem I_m são calculados os gradientes G_x e G_y , utilizando máscaras

unidimensionais de derivada discreta pontual, como mostrado nas Equações (6.1) e (6.2)

$$[-1, 0, 1] \quad (6.1)$$

$$[-1, 0, 1]^T \quad (6.2)$$

A magnitude e a orientação do gradiente são obtidos pelas Equações (6.3) e (6.4)

$$G = \sqrt{G_x^2 + G_y^2} \quad (6.3)$$

$$\theta = \arctan \frac{G_y}{G_x} \quad (6.4)$$

O passo seguinte é responsável por agrupar os pixels de uma determinada região, criando as células. Todas as células criadas na imagem possuem mesmo formato e tamanho. Para cada célula é determinado um histograma com orientação do vetor gradiente dos seus pixels, onde são computados os valores de magnitude de acordo com o ângulo do vetor. O histograma possui uma quantidade finita de divisões, normalmente com nove divisões.

Após a segunda etapa, os blocos são criados através do agrupamento de células de uma certa região. Assim como as células, os blocos também sempre possuem o mesmo formato e tamanho em toda a imagem. Existem áreas dos blocos em que há uma sobreposição proposital com o bloco vizinho, o que torna o método mais eficiente em relação a uma abordagem sem essas sobreposições [67].

Na etapa final, cria-se o descritor que nada mais é do que uma lista dos histogramas de todas as células de todos os blocos. A Figura 6.2 mostra as etapas do algoritmo e a representação final do descritor HoG.

Vale ressaltar que os descritores são invariantes a mudanças homogêneas de brilho da imagem, uma vez que esta variação representa uma adição a todos os pixels da imagem de uma constante, e os descritores são calculados por diferenças de pixels. Quanto a

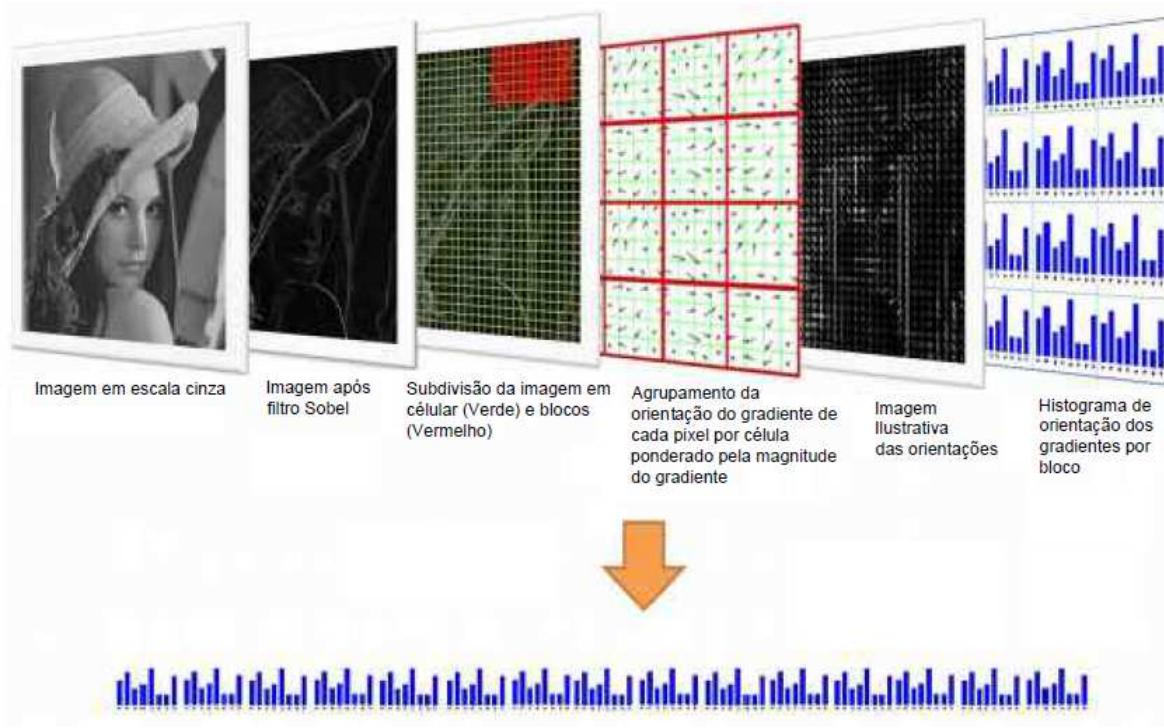


Figura 6.2: Representação gráfica do processo de extração de características HoG.

mudanças homogêneas de contraste, representadas pela multiplicação de todos os pixels por uma constante, elas são corrigidas com a normalização dos descritores.

Variações não lineares, causadas por saturação das câmeras ou por efeito de iluminação de superfícies tridimensionais em diferentes orientações, podem provocar elevada influência sobre as magnitudes dos descritores, mas com pouca influência na orientação. Reduz-se este efeito impondo um valor máximo às magnitudes. Após a normalização, todos os valores acima de um determinado limiar são ajustados para este limiar. Isto é feito para que direções com magnitude muito grande não dominem a representação do descritor.

6.3.2 Dynamic Time Warping - DTW

Dynamic time warping (DTW) é uma técnica bem conhecida e utilizada para encontrar o alinhamento otimizado entre duas sequências, dependentes do tempo, sob certas restrições. Normalmente, as sequências são deformadas de forma não linear para coinci-

dir uma com a outra. Originalmente, DTW foi usada no reconhecimento automático de fala. Na área de mineração de dados e de recuperação de informação a DTW tem sido aplicada com sucesso para tratar automaticamente de deformações temporais e fontes de dados dependentes do tempo com velocidades diferentes [68] e [69].

O objetivo da DTW é comparar duas sequências dependentes do tempo; $X := (x_1, x_2, \dots, x_N)$ de comprimento $N \in \mathbb{N}$ e $Y := (y_1, y_2, \dots, y_M)$ de comprimento $M \in \mathbb{N}$ e calcular o caminho de deformação ótimo entre as duas sequências. O caminho ótimo é escolhido minimizando a distância entre o ponto de teste e o ponto de referência.

Considerando as sequências X e Y , com tamanhos diferentes, o algoritmo calcula a distância absoluta entre os elementos das sequências. O resultado é uma matriz com $M \times N$ elementos, geralmente determinados pela Equação (6.5).

$$d_{i,j} = |x_i - y_j| \quad (6.5)$$

em que: $i = 1, 2, \dots, N$ e $j = 1, 2, \dots, M$.

Na matriz de distâncias, a distância mínima entre duas sequências é determinada utilizando o critério de otimização definido na Equação (6.6).

$$D_{i,j} = d_{i,j} + \min(D_{i-1,j-1}, D_{i-1,j}, D_{i,j-1}) \quad (6.6)$$

em que: $D_{i,j}$ é a distância mínima entre as sequências.

Um caminho deformado é um caminho através da matriz de distâncias, a partir do elemento $D_{1,1}$ até o elemento $D_{M,N}$ formado pelos elementos $D_{i,j}$. A Figura 6.3 mostra o processo da DWT.

De forma mais genérica, para comparar duas características diferentes entre a sequência X e a sequência Y , normalmente é utilizado uma matriz de custo local c . Quando x e y são similares, $c(x, y)$ possui baixo custo. Caso contrário $c(x, y)$ possui alto custo. Assim, o alinhamento entre X e Y ocorre quando obtém o custo total mínimo.

O custo global da deformação entre as sequências é mostrado na Equação (6.7), em que

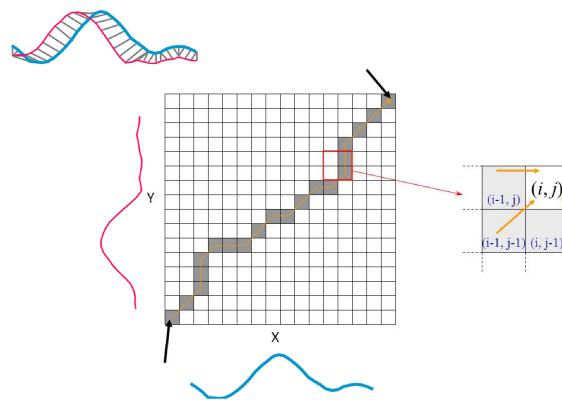


Figura 6.3: Representação gráfica da construção do caminho deformado da DTW.

w_i são os elementos que pertencem ao caminho deformado ótimo e p é a quantidade de elementos que formam o caminho.

$$GC = \frac{1}{p} \sum_{i=1}^p w_i \quad (6.7)$$

6.4 Implementação

O Diagrama de blocos da Figura 6.4 demonstra a etapa proposta para a criação do que será denominado de ”máscara dinâmica”. O histograma de gradientes orientados é calculado para a imagem inscrita na galeria e para a imagem de teste. O HoG das imagens formam vetores de características que são alinhados e comparados pela DTW.

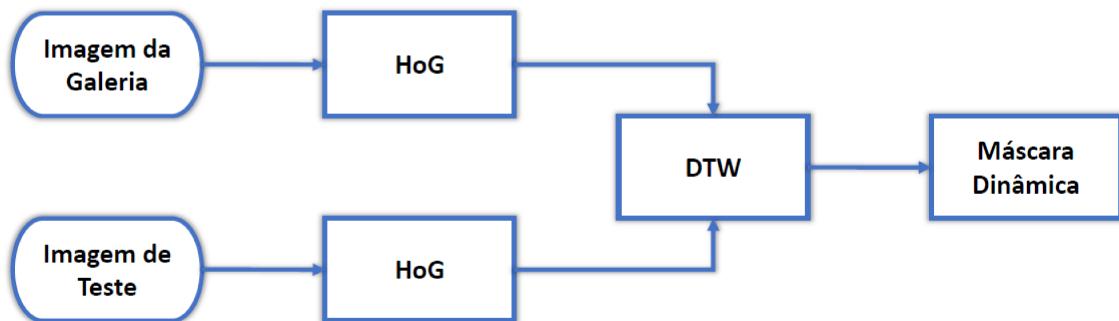


Figura 6.4: Diagrama de blocos do sistema de alinhamento das características dinâmicas.

Os histogramas das células pertencentes à mesma posição espacial da imagem inscrita e da imagem de teste são denominados histogramas correspondentes por fornecerem os vetores de características das regiões correspondentes entre as imagens. As células correspondentes ou histogramas correspondentes que possuem grau de similaridade menor que um limiar são descartadas no processo de reconhecimento. Para isso, a máscara dinâmica é gerada para indicar a posição destas células.

A Figura 6.5, mostra a *template* de uma imagem da galeria, sua máscara de ruído determinada pelo sistema, uma *template* de teste e sua máscara de ruído e, finalmente, a máscara dinâmica que indica a região onde a similaridade entre as imagens é menor que o limiar adotado. Para a máscara dinâmica da Figura 6.5 o limiar adotado foi determinado empiricamente considerando a similaridade máxima encontrada entre as células menos quatro vezes o desvio padrão.

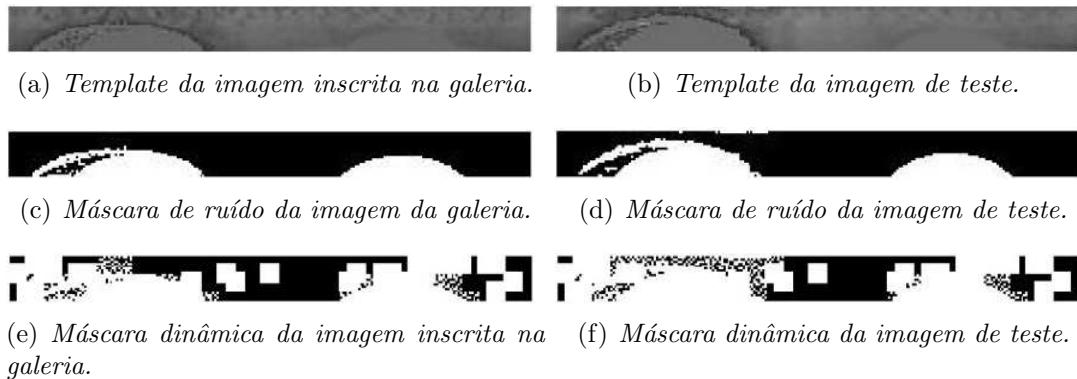


Figura 6.5: Indicação da posição das células menos similares entre as imagens da galeria e da imagem de teste.

6.5 Resultados Experimentais

Os experimentos 2 e 3 da Seção 5.2 do Capítulo 5 foram repetidos para avaliar a eficácia da técnica proposta, porém as máscaras de ruído foram transformadas em máscaras dinâmicas. As novas distribuições de distância de Hamming e as novas curvas ROC, do

experimento 2, que representam a saída do sistema de reconhecimento para os subconjuntos (1), (2) e (3) são apresentadas nas Figuras 6.6 e 6.7, respectivamente.

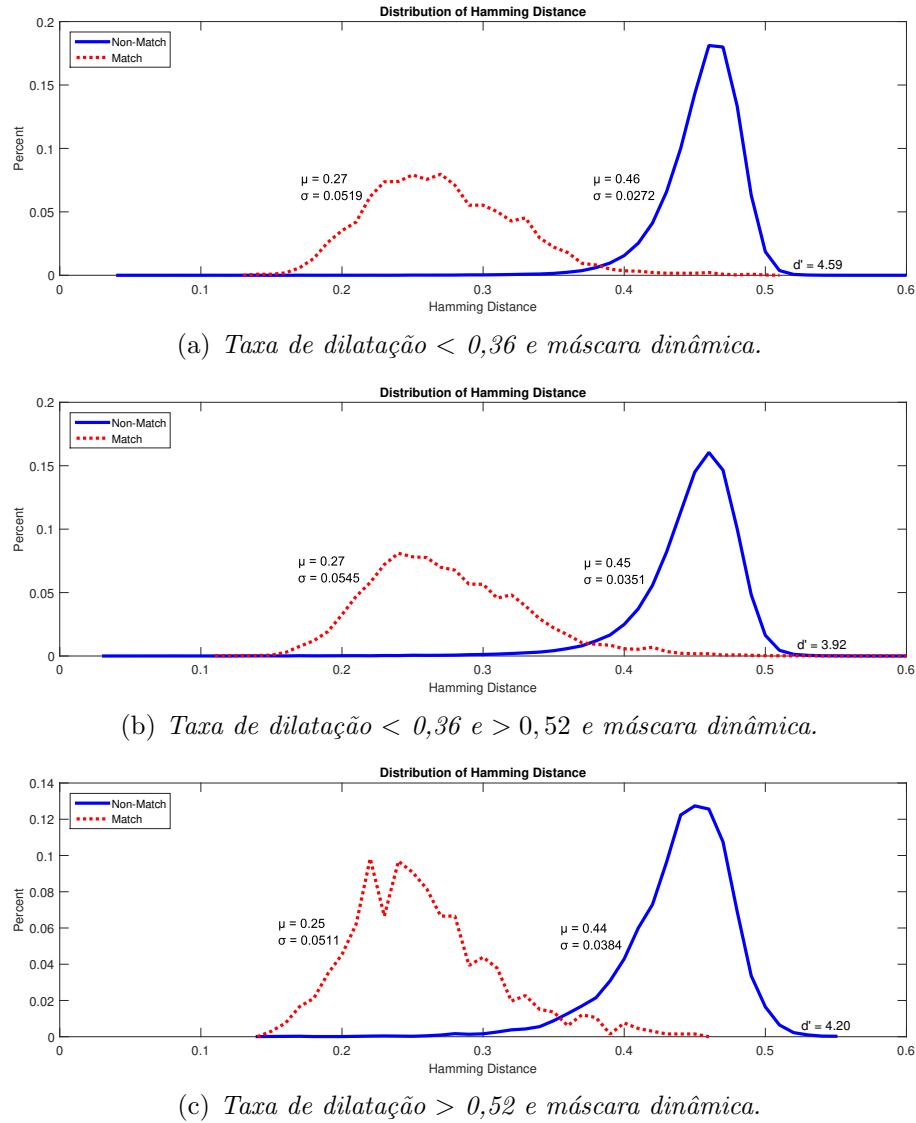


Figura 6.6: Distribuição das distâncias de Hamming de acordo com a taxa de dilatação utilizando máscara dinâmica.

Considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens do Subconjunto (1), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0519. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0272 e a decidibilidade encontrada

foi 4, 59.

Da mesma forma, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens do Subconjunto (2), a média das distribuições correspondentes foi de 0, 27, com desvio padrão de 0, 0545. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0, 45, com desvio padrão de 0, 0351 e a decidibilidade encontrada foi 3, 92.

Finalmente, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens do Subconjunto (3), a média das distribuições correspondentes foi de 0, 25, com desvio padrão de 0, 0511. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0, 44, com desvio padrão de 0, 0384 e a decidibilidade encontrada foi 4, 20.

As curvas ROC da Figura 6.7, determinam as EER para os três subconjuntos, considerando o desempenho da máscara dinâmica. Para os Subconjuntos (1), (2) e (3) as EER foram de 2, 51%, 4, 63% e 4, 84%, respectivamente. A Figura 6.7 também mostra a EER de 4, 64% referente à comparação entre todas as imagens dos Subconjuntos (1), (2) e (3).

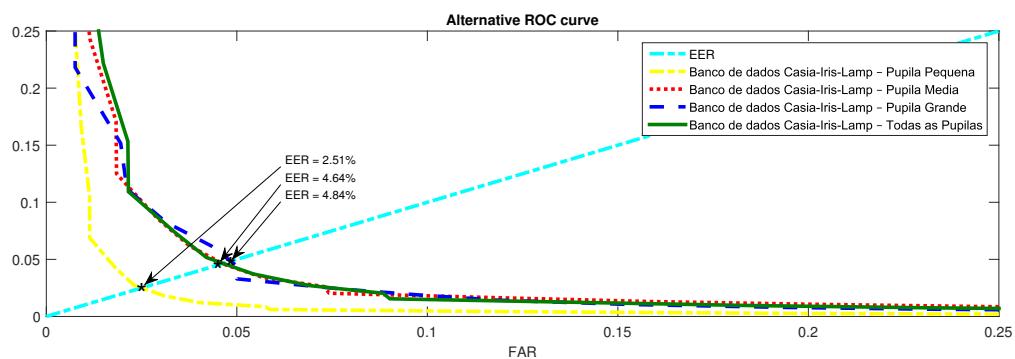


Figura 6.7: ROC para os três intervalos de taxa de dilatação utilizando máscara dinâmica.

As matrizes de confusão, utilizando as máscaras dinâmicas, para cada subconjunto são mostradas na Tabela 6.1. O sistema apresenta uma precisão e um especificidade de 90% para o Subconjunto (1), onde a taxa de dilatação é a menor. O Subconjunto (2) possui uma precisão e uma especificidade de 89%. O Subconjunto (3) possui uma precisão e uma especificidade de 87%. A sensibilidade para os Subconjuntos (1), (2) e (3) foi de 98%, 96%

e 87%, respectivamente.

Tabela 6.1: *Matriz de confusão do melhor resultado para cada subconjunto.*

(a) Imagens com menor taxa de dilatação.

$TP = 1.971,70$	$FP = 9.356,00$	$P_p = 0,17$
$FN = 37,64$	$TN = 90.992,00$	$P_n = 0,99$
$S_t = 0,98$	$S_f = 0,90$	$A = 0,90$

(b) Imagens com taxa de dilatação intermediária.

$TP = 2.996,70$	$FP = 20.508,00$	$P_p = 0,12$
$FN = 116,06$	$TN = 179.140,00$	$P_n = 0,99$
$S_t = 0,96$	$S_f = 0,89$	$A = 0,89$

(c) Imagens com maior taxa de dilatação.

$TP = 333,18$	$FP = 699,54$	$P_p = 0,32$
$FN = 10,78$	$TN = 4.717,40$	$P_n = 0,99$
$S_t = 0,96$	$S_f = 0,87$	$A = 0,87$

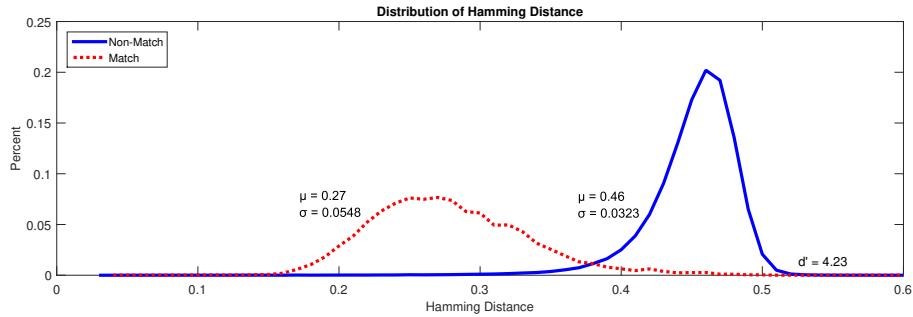
As novas distribuições de distância de Hamming e as novas curvas ROC, do experimento 3, que representam a saída do sistema de reconhecimento para os Subconjuntos (1 e 2), (1 e 3) e (2 e 3) são apresentadas nas Figuras 6.8 e 6.9, respectivamente.

Considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens dos Subconjuntos (1) e (2), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0548. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0323 e a decidibilidade encontrada foi 4,23.

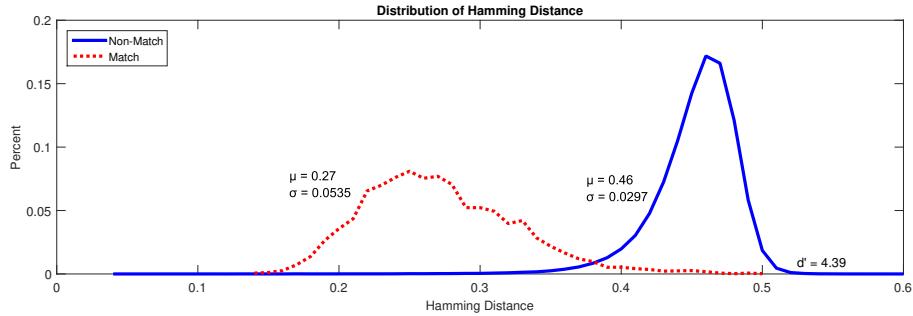
Da mesma forma, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens dos Subconjuntos (1) e (3), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0535. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0297 e a decidibilidade encontrada foi 4,39.

Finalmente, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens dos Subconjuntos (2) e (3), a média das distribuições cor-

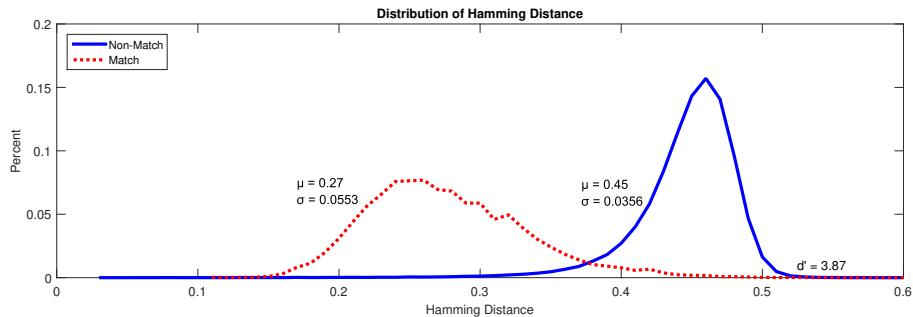
respondentes foi de 0,27, com desvio padrão de 0,0553. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,45, com desvio padrão de 0,0356 e a decidibilidade encontrada foi 3,87.



(a) *Comparações entre os Subconjuntos (1) e (2) utilizando máscara dinâmica.*



(b) *Comparações entre os Subconjuntos (1) e (3) utilizando máscara dinâmica.*



(c) *Comparações entre os Subconjuntos (2) e (3) utilizando máscara dinâmica.*

Figura 6.8: *Distribuição das distâncias de Hamming entre os Subconjuntos (1), (2) e (3) utilizando máscara dinâmica.*

As curvas ROC da Figura 6.9 determinam as EER para os três subconjuntos, considerando o desempenho da máscara dinâmica. Para os Subconjuntos (1 e 2), (1 e 3) e (2 e 3) as EER foram de 4,30%, 3,36% e 5,04%, respectivamente. A Figura 6.9 também mostra

a EER de 4,64% referente à comparação entre todas as imagens dos Subconjuntos (1), (2) e (3).

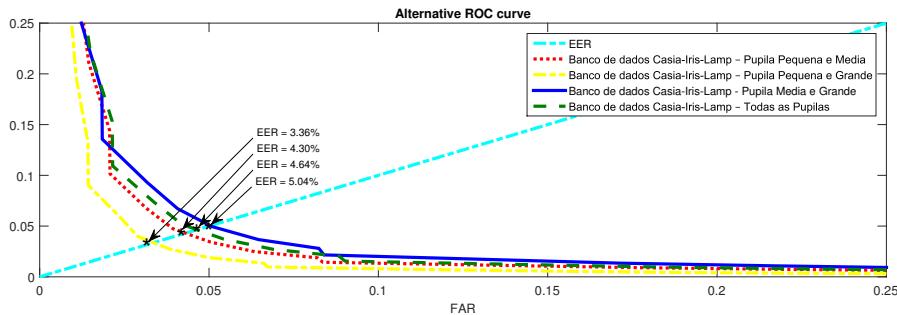


Figura 6.9: *ROC para a comparação entre os subconjuntos utilizando máscara dinâmica.*

As matrizes de confusão da comparação entre os subconjuntos, utilizando as máscara dinâmicas, são mostradas na Tabela 6.2. O sistema apresenta uma precisão e um especificidade de 91% para as comparações entre as imagens dos Subconjuntos (1) e (2). A comparação entre as imagens dos Subconjunto (1) e (3) possui uma precisão e uma especificidade de 88%. A comparação entre as imagens dos Subconjuntos (2) e (3) possui uma precisão e uma especificidade de 88%.

A sensibilidade, a especificidade e a precisão para a comparação entre todas as imagens dos Subconjuntos (1), (2) e (3) foi de 96%, 86% e 86%, respectivamente.

6.6 Discussão

Os resultados experimentais indicam claramente que a técnica proposta não é indicada para comparações entre as imagens com taxas de dilatação próximas. Na repetição do experimento 2, utilizando a máscara dinâmica, os resultados da decidibilidade e da EER pioraram. Para o subconjunto (1) a decidibilidade passou de 5,53, sem máscara para 4,59, com máscara. Para o subconjunto (2) a decidibilidade passou de 4,78, sem máscara para 3,92, com máscara. Finalmente, para o subconjunto (3) a decidibilidade passou de 5,24, sem máscara para 4,20, com máscara.

Tabela 6.2: *Matriz de confusão do melhor resultado para comparação entre subconjuntos.*

(a) Distribuição das distâncias de Hamming entre os Subconjuntos (1) e (2).

$TP = 6.581,30$	$FP = 48.844,00$	$P_p = 0,11$
$FN = 271,04$	$TN = 533.990,00$	$P_n = 0,99$
$S_t = 0,96$	$S_f = 0,91$	$A = 0,91$

(b) Distribuição das distâncias de Hamming entre os Subconjuntos (1) e (3).

$TP = 2.415,50$	$FP = 17.980,00$	$P_p = 0,11$
$FN = 57,60$	$TN = 13.650,00$	$P_n = 0,99$
$S_t = 0,97$	$S_f = 0,88$	$A = 0,88$

(c) Distribuição das distâncias de Hamming entre os Subconjuntos (2) e (3).

$TP = 3.997,70$	$FP = 30.529,00$	$P_p = 0,11$
$FN = 156,44$	$TN = 242.950,00$	$P_n = 0,99$
$S_t = 0,96$	$S_f = 0,88$	$A = 0,88$

Para o subconjunto (1) a EER passou de 0, 98%, sem máscara para 2, 51%, com máscara.

Para o subconjunto (2) a EER passou de 1, 76%, sem máscara para 4, 63%, com máscara.

Finalmente, para o subconjunto (3) a EER passou de 1, 55%, sem máscara para 4, 84%, com máscara.

Esse resultado já era esperado, pois a taxa de dilatação das imagens de cada subconjunto são próximas e, portanto, qualquer perda de informação provocada pela máscara dinâmica prejudica ainda mais a performance do sistema, conforme comprova também os valores das matrizes de confusão.

Na repetição do experimento 3, utilizando a máscara dinâmica, as comparações entre as imagens dos Subconjuntos (1 e 2) e (2 e 3) também não tiveram melhoria nos resultados. Contudo, os resultados comprovam que a utilização da técnica proposta é útil no teste de comparação que envolve as imagens dos Subconjuntos (1) e (3). Estes subconjuntos são constituídos pelas imagens com menores e maiores taxas de dilatação, portanto a variação da área da íris e sua deformação não linear estão mais evidentes.

A decidibilidade e a EER para a comparação entre as imagens dos Subconjuntos (1) e

(3), sem o uso da máscara dinâmica foi de 3,5 e 9,69%, respectivamente. Com o uso da máscara dinâmica a decidibilidade e a EER passaram para 4,39 e 3,36% respectivamente.

A matriz de confusão mostra um aumento no valor preditivo positivo e na sensibilidade, de 0,078 para 0,11 e de 0,83 para 0,97, respectivamente. Esse fato indica uma taxa maior de verdadeiro positivo, porém a precisão do sistema fica menor devido ao aumento na taxa de falso positivo, indicada pela especificidade que passou de 0,97 para 0,88.

6.7 Considerações Finais

O argumento teórico apresentado foi comprovado nos experimentos. Com o método proposto foi possível aumentar a decidibilidade e diminuir a EER do sistema de reconhecimento da íris para o caso em que a taxa de dilatação entre as imagens são bem diferentes. No caso de imagens com taxas de dilatação próximas o método não é indicado, pois a perda de informação provocada pela máscara dinâmica prejudica a performance do sistema.

Potencialmente, os sistemas de reconhecimento de íris podem ser utilizados em larga escala e com alta precisão. Assim, considerar a dinâmica da íris no processo biométrico pode ser a chave para o desenvolvimento de um sistema verdadeiramente automático, confiável e independente da variabilidade intraclass.

Conclusões, Contribuições e Sugestões de Trabalhos Futuros

7.1 Resumo das Implementações

Nos quatro primeiros capítulos deste trabalho, foram descritas todas as etapas de processamento de um sistema de reconhecimento de íris utilizando métodos tradicionais. Além disso, os resultados da implementação, as abordagens adotadas e as dificuldades encontradas em cada etapa foram apresentadas e discutidas.

As etapas tradicionais correspondem à segmentação, normalização, codificação e comparação. A segmentação da região da íris foi descrita no capítulo 2. Nesta etapa os métodos implementados foram a transformada circular de Hough (TCH) para a detecção da íris na imagem do olho, a transformada linear de Hough para a detecção das pálpebras e o estabelecimento de um limiar em escala cinza para detectar a interferência dos cílios no interior da região da íris. Utilizando as imagens da base de dados CASIA-Iris-V1 e CASIA-IRIS-Lamp, a etapa de segmentação obteve 85% e 75% de segmentações corretas, respectivamente.

No capítulo 3, foi descrito o método utilizado na etapa de normalização, responsável por gerar uma imagem retangular com dimensões constantes independente dos tamanhos da pupila e da íris, detectados na etapa anterior. O método implementado foi proposto por John Daugman, denominado de *homogeneous rubber sheet*. Esse método modela a região

da íris como um anel de borracha e utiliza uma amostragem uniforme dos pixels da íris.

Todas as imagens da base de dados CASIA-Iris-V1 e CASIA-IRIS-Lamp foram normalizadas com sucesso. Ao final dessa etapa, a representação retangular da região da íris possui dimensões de 20×240 pixels e uma máscara de ruído com as mesmas dimensões foi gerada para representar as regiões que possuem interferência das pálpebras e cílios.

No capítulo 4, as características da íris foram extraídas da representação normalizada e codificadas. A extração das características foi implementada utilizando um filtro Log-Gabor 1D e a quantização da fase do sinal de saída desse filtro gerou a *template* binária de dimensões 20×480 pixels. Essa *template* representa o código da íris.

Para realizar a comparação entre duas *templates* foi utilizada como métrica a distância de Hamming. O valor da distância de Hamming fornece uma medida da quantidade de bits que são correspondentes entre as duas *templates*. Um limiar define se as duas *templates* são provenientes da mesma íris ou não. As inconsistências rotacionais também foram tratadas nesta etapa.

Para as imagens codificadas da base de dados CASIA-Iris-V1 e CASIA-IRIS-Lamp, foram utilizadas até oito deslocamentos para esquerda e para a direita, e apenas o melhor resultado da distância de Hamming foi considerado. Um histograma das distâncias de Hamming foi gerado para mostrar o grau de sobreposição entre as amostras intraclasse e interclasse.

No capítulo 5 o sistema implementado foi testado utilizando 608 imagens do conjunto CASIA-Iris-V1 que geraram 1.536 comparações intraclasse e 183.760 comparações interclasse e 1.753 imagens do conjunto CASIA-IRIS-Lamp que geraram 28.608 comparações intraclasse e 1.521.324 comparações interclasse.

Com o objetivo de demonstrar a influência dos movimentos do tecido da íris no processo de reconhecimento biométrico, três experimentos foram desenvolvidos e os parâmetros decidibilidade e EER foram utilizados para medir a capacidade do sistema em separar as distribuições intraclasse e interclasse.

No primeiro experimento a decidibilidade foi de 5,19 e 4,76 para os conjuntos CASIA-Iris-V1 e CASIA-IRIS-Lamp, respectivamente. A EER, foi de 0,75% e 2,16% para os

conjuntos CASIA-Iris-V1 e CASIA-IRIS-Lamp, respectivamente. Esses resultados sugerem de forma notória que o conjunto CASIA-IRIS-Lamp está mais sujeito a erros.

No segundo experimento, o conjunto CASIA-IRIS-Lamp foi dividido empiricamente em três grupos de acordo com a taxa de dilatação, ou seja, a razão entre o raio da pupila e o raio da íris. O Subconjunto (1), constituído pelas imagens com taxa de dilatação menor do que 0,36, apresentou decidibilidade de 5,53 e EER de 0,98%. O Subconjunto (2), constituído pelas imagens com taxa de dilatação maior do que 0,36 e menor do que 0,52, apresentou decidibilidade de 4,78 e EER de 1,76%. O Subconjunto (3), constituído pelas imagens com taxa de dilatação maior do que 0,52, apresentou decidibilidade de 5,24 e EER de 1,55%.

Os resultados do experimento 2 indicam que o estado de contração e dilatação da íris interferem na precisão do sistema de reconhecimento. O sistema apresentou as melhores respostas para as imagens dos Subconjuntos (1) e (3). Nestes dois subconjuntos a quantidade de informação discriminante é maior, pois para o primeiro caso a área da íris é proporcionalmente maior e no segundo caso a compressão das estruturas da íris formam uma textura mais rica em bordas.

No terceiro experimento, os códigos comparados pertenciam, obrigatoriamente, à subconjuntos diferentes, ou seja, as comparações foram realizadas entre imagens com taxas de dilatação bem diferentes. A decidibilidade e a EER para as comparações entre os Subconjuntos, (1) e (3), (1) e (2) e (2) e (3) são 3,5 e 9,69%, 4,44 e 3,52% e 3,79 e 2,64%, respectivamente.

Os resultados do terceiro experimento evidenciaram ainda mais a influência dos movimentos da pupila no sistema de reconhecimento. Esse fato comprovou que o modelo *homogeneous rubber sheet* realmente não é adequado para os sistemas que utilizam imagens com variações no estado da íris.

A Tabela 7.1 resume os resultados encontrados nos três experimentos realizados. Quanto maior a decidibilidade, maior é a separação entre as distribuições intraclasse e interclasse e, consequentemente, maior a precisão no reconhecimento. Quanto menor a EER, maior é a capacidade do sistema em classificar corretamente uma amostra.

Tabela 7.1: *Resultados dos três experimentos realizados - Resumo.*

Experimento	Imagens	decidibilidade	EER
1	CASIA-Iris-V1	5, 19	0, 75%
	CASIA-IRIS-Lamp	4, 76	2, 16%
2	Subconjunto (1)	5, 53	0, 98%
	Subconjunto (2)	4, 78	1, 76%
	Subconjunto (3)	5, 24	1, 55%
3	Subconjuntos (1) e (3)	3, 50	9, 69%
	Subconjuntos (1) e (2)	4, 44	3, 52%
	Subconjuntos (2) e (3)	3, 79	2, 64%

No capítulo 6, foi apresentado o método proposto para aumentar a decidibilidade e diminuir a EER. O método foi fundamentado na criação de máscaras dinâmicas, responsáveis por descartar as regiões da íris com baixo grau de similaridade, considerando sua deformação não linear e o desalinhamento das características discriminantes em íris que se encontram em estados diferentes.

Todos os detalhes para gerar a máscara dinâmica, utilizado o histograma de gradientes orientados e o alinhamento dos vetores resultantes, alinhados e comparados pelo algoritmo *Dynamic Time Warping*, foram apresentados. Os resultados obtidos foram satisfatórios para o caso de imagens em estados diferentes e são apresentados, de forma resumida na Tabela 7.2.

A Tabela 7.2 também permite a comparação direta dos resultados obtidos com e sem o uso do método proposto, ou seja, com e sem a influência da máscara dinâmica.

Tabela 7.2: *Resultados dos experimentos realizados utilizando máscara dinâmica - Resumo.*

Experimento	Imagens	Com máscara		Sem máscara	
		decidibilidade	EER	decidibilidade	EER
1	CASIA-Iris-V1	-	-	5, 19	0, 75%
	CASIA-IRIS-Lamp	4, 17	4, 64%	4, 76	2, 16%
2	Subconjunto (1)	4, 59	2, 51%	5, 53	0, 98%
	Subconjunto (2)	3, 92	4, 63%	4, 78	1, 76%
	Subconjunto (3)	4, 20	4, 84%	5, 24	1, 55%
3	Subconjuntos (1) e (3)	4, 39	3, 36%	3, 50	9, 69%
	Subconjuntos (1) e (2)	4, 23	4, 30%	4, 44	3, 52%
	Subconjuntos (2) e (3)	3, 87	5, 04%	3, 79	2, 64%

7.2 Conclusões e Contribuições

A construção de um sistema de reconhecimento biométrico, utilizando técnicas tradicionais pode ser considerada a primeira contribuição deste trabalho. Juntamente com o desenvolvimento do sistema, destaca-se a apresentação do estado da arte que serve como referência para trabalhos futuros e como fonte de consulta para trabalhos na área de biometria da íris.

Outra contribuição extremamente importante foi a avaliação quantitativa da influência dos movimentos pupilares no processo de reconhecimento. A dinâmica pupilar foi considerada em todas as etapas do processamento e seu impacto na decidibilidade e na EER foi avaliado para diferentes estados de contração e dilatação da íris.

Desse modo, ficou explícito que o modelo tradicional de normalização não é o mais adequado para sistemas que utilizam imagens dinâmicas. O processo de amostragem também é influenciado pela deformação não linear da estrutura da íris, pois o alinhamento entre as características da imagem da galeria e da imagem de teste não se mantém o mesmo para íris em diferentes estados de contração.

Entretanto, a principal contribuição deste trabalho foi o método proposto para melhorar o desempenho do sistema quando se compara códigos de íris em estados bem diferentes de contração. O uso da técnica *Dynamic Time Warping* para o alinhamento dos vetores de histogramas orientados na etapa de comparação foi inovador e eficaz, conforme mostraram os resultados obtidos.

7.3 Sugestões de Trabalhos Futuros

Todos os objetivos iniciais deste trabalho foram atendidos, no entanto o seu desenvolvimento ofereceu condições para a realização de outros trabalhos, como por exemplo:

- Implementação do sistema de reconhecimento, juntamente com a técnica proposta, em linguagem de programação compilada, específica para processamento de imagens,

como por exemplo C++, associada à biblioteca OpenCV de visão computacional.

- Utilização de outro banco de imagens dinâmicas para que os resultados sejam comparados com os obtidos neste trabalho.
- Devido à grande quantidade de imagens testadas, alguns parâmetros do Gradiente de histogramas orientado não foram modificados. Por exemplo, o tamanho das células, dos blocos, da sobreposição dos blocos e as máscaras de gradiente. O mesmo vale para o limiar utilizado na comparação realizada pelo algoritmo da *Dynamic Time Warping*.
- Utilização de técnicas diferentes em todas as etapas do sistema de reconhecimento, principalmente novas técnicas de comparação e alinhamento para a comparação dos resultados com os obtidos neste trabalho.

7.4 Principais Publicações

Artigos publicados:

- Latin America Transactions, IEEE (Revista IEEE América Latina) - ISSN 1548-0992.
Iris Movements: The Best State to Dynamic Biometric Recognition Process. Vol 14, Issue 5, May 2016.
- Latin America Transactions, IEEE (Revista IEEE América Latina) - ISSN 1548-0992.
Influence of Source Light in Clinical Parameters of Pupillary Cycle. Vol. 13, Issue 12, December 2015.
- Conferência de Estudos em Engenharia Elétrica (CEEL) 2014 - ISSN 2178-8308.
Sistema embarcado para controle de iluminação na Aquisição de Ciclos Pupilares.
- Conferência de Estudos em Engenharia Elétrica (CEEL) 2014 - ISSN 2178-8308.
Fundamentos da Técnica de Fluxo Óptico e sua Aplicação em Pupilometria.

Artigos Submetidos:

- Pattern Recognition Letters 2015 - ISSN 0167-8655. Analysis of the Influence of Pupil Dilatation and Contraction in Biometric Recognition.

Referências Bibliográficas

- [1] John Daugman. How Iris Recognition Works. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1):715–739, 2004.
- [2] Harry J. Wyatt. A minimum-wear-and-tear meshwork for the iris. *Vision Research*, 40(16):2167–2176, jul 2000.
- [3] Li Ma, Tieniu Tan, Yunhong Wang, and Dexin Zhang. Efficient iris recognition by characterizing key local variations. *IEEE Transactions on Image Processing*, 13(6):739–750, 2004.
- [4] Vitor F. Pamplona, Manuel M. Oliveira, and Gladimir V. G. Baranowski. Photorealistic models for pupil light reflex and iridal pattern deformation. *ACM Transactions on Graphics*, 28(4):1–12, 2009.
- [5] John Daugman. New methods in iris recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 37(5):1167–1175, 2007.
- [6] R.P. Wildes, J.C. Asmuth, G.L. Green, S.C. Hsu, R.J. Kolczynski, J.R. Matey, and S.E. McBride. A system for automated iris recognition. *Proceedings of 1994 IEEE Workshop on Applications of Computer Vision*, pages 121–128, 1994.

- [7] Shinyoung Lim, Kwanyong Lee, Okhwan Byeon, and Taiyun Kim. Efficient iris recognition through improvement of feature vector and classifier. *ETRI Journal*, 23(2):61–70, 2001.
- [8] Zaheera Zainal Abidin, Mazani Manaf, Abdul Samad Shibghatullah, Siti Hajar Atika Mohd Yunos, Syarulnaziah Anawar, and Zakiah Ayop. Iris Segmentation Analysis using Integro-Differential Operator and Hough Transform in Biometric System. *Journal of Telecommunication, Electronic and Computer Engineering*, 4(2):41–48, 2012.
- [9] Karen Hollingsworth, Kevin W. Bowyer, and Patrick J. Flynn. Pupil dilation degrades iris biometric performance. *Computer Vision and Image Understanding*, 113(1):150–157, 2009.
- [10] Karen P. Hollingsworth, Kevin W. Bowyer, and Patrick J. Flynn. The best bits in an Iris code. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(6):964–973, 2009.
- [11] Debasis Dey, Somnath and Samanta. Improved Feature Processing for Iris Biometric Authentication System. *International Journal of Computer Systems Science and Engineering (IJCSSE)*, *World Academy of Science*, 4(3):455–462, 2010.
- [12] Jun-Zhou Huang, Tie-Niu Tan, Li Ma, and Yun-Hong Wang. Phase Correlation Based Iris Image Registration Model. *Journal of Computer Science and Technology*, 20(3):419–425, may 2005.
- [13] Jason Thornton, Marios Savvides, and B.V.K. Kumar. A Bayesian Approach to Deformed Pattern Matching of Iris Images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(4):596–606, apr 2007.
- [14] J.G. Daugman. High confidence visual recognition of persons by a test of statistical independence. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(11):1148–1161, 1993.

- [15] Zhuoshi Wei, Tieniu Tan, and Zhenan Sun. Nonlinear Iris Deformation Correction Based on Gaussian Model. In *Advances in Biometrics*, pages 780–789. Springer Berlin Heidelberg, Berlin, Heidelberg, 2007.
- [16] Libor Masek. Recognition of human iris patterns for biometric identification. *University of Western Australia*, 2003.
- [17] M S Nixon and A S Aguado. Feature Extraction and Image Processing. *Academic Press*, page 88, 2008.
- [18] Milena Bueno Pereira. Uma aplicação de algoritmos genéticos para melhorar a confiabilidade de um sistema de reconhecimento de íris. *UFU*.
- [19] Pan Lili and Xie Mei. The algorithm of iris image preprocessing. *Proceedings - Fourth IEEE Workshop on Automatic Identification Advanced Technologies, AUTO ID 2005*, 2005:134–138, 2005.
- [20] GuangZhu Xu, ZaiFeng Zhang, and YiDe Ma. Automatic iris segmentation based on local areas. *Proceedings - International Conference on Pattern Recognition*, 4(c):505–508, 2006.
- [21] B. Bonney, R. Ives, and D. Etter. Iris pattern extraction using bit planes and standard deviations. In *Conference Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers, 2004.*, volume 1, pages 582–586, 2004.
- [22] H M El-Bakry. Fast iris detection for personal identification using modular neural networks. In *Circuits and Systems, 2001. ISCAS 2001. The 2001 IEEE International Symposium on*, volume 3, pages 581 –584 vol. 2, 2001.
- [23] Zhaofeng He, Tieniu Tan, and Zhenan Sun. Iris Localization via Pulling and Pushing. In *18th International Conference on Pattern Recognition (ICPR'06)*, volume 1, pages 366–369. IEEE, 2006.

- [24] Wai-kin Kong and David Zhang. Detecting Eyelash and Reflection for Accurate Iris Segmentation. *International Journal of Pattern Recognition and Artificial Intelligence*, 17:1025–1034, 2003.
- [25] Anirudh Sivaraman. Iris segmentation using daugman’s integrodifferential operator. <http://www.mathworks.com/matlabcentral/fileexchange/15652-iris-segmentation-using-daugman-s-integrodifferential-operator>, 20 Jul 2007 (Updated 31 Jul 2015).
- [26] R.P. Wildes. Iris recognition: an emerging biometric technology. *Proceedings of the IEEE*, 85(9):1348–1363, 1997.
- [27] Lenina Birgale and Manesh Kokare. Iris recognition without iris normalization. 2010.
- [28] Xufong Li and Mei Xie. A novel algorithm of human iris recognition. *ISCIT 2005 - International Symposium on Communications and Information Technologies 2005, Proceedings*, I:1190–1193, 2005.
- [29] Kevin W Bowyer, Karen Hollingsworth, and Patrick J Flynn. Image understanding for iris biometrics: A survey. *Computer Vision and Image Understanding*, 110(2):281–307, may 2008.
- [30] M Vatsa, R Singh, and A Noore. Reducing the False Rejection Rate of Iris Recognition Using Textural and Topological Features. *International Journal of Signal Processing*, 2(2):66–72, 2005.
- [31] Yong Zhu Yong Zhu, Tieniu Tan Tieniu Tan, and Yunhong Wang Yunhong Wang. Biometric personal identification based on iris patterns. *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*, 2(59825105):801–804, 2000.
- [32] Jaemin Kim, Seongwon Cho, Jinsu Choi, and Robert J Marks II. Iris Recognition Using Wavelet Features. *Journal of VLSI Signal Processing*, 38:147–156, 2004.
- [33] Zhenan Sun and Tieniu Tan. Ordinal measures for iris recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(12):2211–2226, 2009.

- [34] Li Ma, Tieniu Tan, Yunhong Wang, and Dexin Zhang. Local intensity variation analysis for iris recognition. *Pattern Recognition*, 37(6):1287–1298, 2004.
- [35] W. W. Boles and B. Boashash. A Human Identification Technique Using Images of the Iris and Wavelet Transform. *IEEE Transactions on Signal Processing*, 46(4):1185–1188, 1998.
- [36] Lu Chenhong, Lu and Zhaoyang. Efficient iris recognition by computing discriminable textons. In *International Conference on Neural Networks and Brains*, pages 1164–1167, 2005.
- [37] Chia-te Chou, Sheng-wen Shih, Wen-shiung Chen, and Victor W Cheng. Iris Recognition with Multi-Scale Edge-Type Matching Department of Electrical Engineering. In *The 18th International Conference on Pattern Recognition*, pages 18–21, 2006.
- [38] Peng Yao Peng Yao, Jun Li Jun Li, Xueyi Ye Xueyi Ye, Zhenquan Zhuang Zhenquan Zhuang, and Bin Li Bin Li. Iris Recognition Algorithm Using Modified Log-Gabor Filters. *18th International Conference on Pattern Recognition (ICPR'06)*, 4, 2006.
- [39] Erik Rydgren, Thomas Ea, Frédéric Amiel, Florence Rossant, and Amara Amara. Iris Feature Extraction Using Wavelet Packets. In *IEEE*, pages 861–864, 2004.
- [40] E. Krichen, M.A. Mellakh, S. Garcia-Salicetti, and B. Dorizzi. Iris identification using wavelet packets. In *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004.*, pages 335–338 Vol.4, 2004.
- [41] Jason Thornton, Marios Savvides, and B. V K Vijaya Kumar. An evaluation of iris pattern representations. *IEEE Conference on Biometrics: Theory, Applications and Systems, BTAS'07*, 2007.
- [42] Huifang Huang and Guangshu Hu. Iris recognition based on adjustable scale wavelet transform. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, 7:7533–7536, 2005.

- [43] Dpto De Matematica Aplicada, E T S I Telecomunicacion, and Universidad Politecnica De Madrid. Multiscale analysis for iris biometrics. *Security Technology, 2002.* . . . , (2):35–38, 2002.
- [44] Onsy Abdel Alim and Maha Sharkas. Iris recognition using discrete wavelet transform and artificial neural networks. In *Midwest Symposium on Circuits and Systems*, number 1, pages 337–340, 2004.
- [45] Jain Jang Jain Jang, Kang Ryoung Park Kang Ryoung Park, Jinho Son Jinho Son, and Yillbyung Lee Yillbyung Lee. A study on multi-unit iris recognition. *ICARCV 2004 8th Control, Automation, Robotics and Vision Conference, 2004.*, 2, 2004.
- [46] Zhenan Sun, Yunhong Wang, Tieniu Tan, and Jiali Cui. Cascading statistical and structural classifiers for iris recognition. In *Image Processing, 2004. ICIP '04. 2004 International Conference on*, volume 2, pages 1261–1264 Vol.2, 2004.
- [47] Ya-Ping Huang Ya-Ping Huang, Si-Wei Luo Si-Wei Luo, and En-Yi Chen En-Yi Chen. An efficient iris recognition system. *Proceedings. International Conference on Machine Learning and Cybernetics*, 1, 2002.
- [48] Vivekanand Dorairaj. Performance evaluation of iris-based recognition system implementing pca and ica encoding techniques. In *Defense and Security*, number 304, pages 51–58, 2005.
- [49] Li Ma, Tieniu Tan, Yunhong Wang, and Dexin Zhang. Personal identification based on iris texture analysis. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(12):1519–1533, 2003.
- [50] Chia Te Chu and Ching-Han Chen. High Performance Iris Recognition based on LDA and LPCC. In *Proceedings of the 17th IEEE International Conference on Tools with Artificial Intelligence*, volume 1, pages 3–7, 2005.
- [51] Maki Murakami and Hironobu Takano. Real-time Iris Recognition by a Rotation Spreading Neural Network. *Image (Rochester, N.Y.)*, pages 283–289, 2003.

- [52] R.W. Ives, a.J. Guidry, and D.M. Etter. Iris recognition using histogram analysis. *Conference Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers, 2004.*, 1:562–566, 2004.
- [53] Hong-ying Gu, Yue-ting Zhuang, and Yun-he Pan. An iris recognition method based on multi-orientation features and Non-symmetrical SVM. *Journal of Zhejiang University SCIENCE*, 6A(5):428–432, 2005.
- [54] S. Mahdi Hosseini, Babak N. Araabi, and Hamid Soltanian-Zadeh. Shape Analysis of Stroma for Iris Recognition. *Advances in Biometrics*, 4642:790–799, 2007.
- [55] Yingzi Du. Using 2D Log-Gabor spatial filters for iris recognition. 6202:62020F–62020F–8, 2006.
- [56] Chengqiang Liu and Mei Xie. Iris Recognition Based on DLDA. In *18th International Conference on Pattern Recognition (ICPR'06)*, pages 489–492. IEEE, 2006.
- [57] Emine Krichen, Lorène Allano, Sonia Garcia-Salicetti, and Bernadette Dorizzi. Specific Texture Analysis for Iris Recognition. In *Audio- and Video-Based Biometric Person Authentication*, pages 23–30, 2005.
- [58] Kaushik Roy and Prabir Bhattacharya. Iris recognition with support vector machines. In *Advances in Biometrics*, pages 486–492. Springer, 2005.
- [59] Raul Sanchez-Reillo and Carmen Sanchez-Avila. Iris recognition with low template size. *Audio- and Video-Based Biometric Person Authentication, Proceedings*, 2091:324–329, 2001.
- [60] L Ma, Y H Wang, and T N Tan. Iris recognition using circular symmetric filters. *16th International Conference on Pattern Recognition, Vol II, Proceedings*, pages 414–417, 2002.
- [61] Xianchao Qiu, Zhenan Sun, and Tieniu Tan. Coarse Iris Classification by Learned Visual. pages 770–779. 2007.

- [62] Li Yu, Kuanquan Wang, and David Zhang. A novel method for coarse iris classification. In *Advances in Biometrics*, pages 404–410. Springer, 2005.
- [63] J Daugman and C Downing. Epigenetic randomness, complexity and singularity of human iris patterns. *Proceedings. Biological sciences / The Royal Society*, 268(1477):1737–40, 2001.
- [64] Ruud M. Bolle, Sharath Pankanti, Jonathan H. Connell, and Nalini K. Ratha. Iris individuality: A partial iris model. *Proceedings - International Conference on Pattern Recognition*, 2:927–930, 2004.
- [65] Alan V. Oppenheim and Jae S. Lim. Importance of Phase in Signals. *Proceedings of the IEEE*, 69(5):529–541, 1981.
- [66] Donald M Monro, Soumyadip Rakshit, and Dexin Zhang. DCT-based iris recognition. *IEEE transactions on pattern analysis and machine intelligence*, 29(4):586–95, 2007.
- [67] Navneet Dalal and Bill Triggs. Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 886–893. IEEE, 2005.
- [68] Qian Chen, Guyu Hu, Fanglin Gu, and Peng Xiang. Learning optimal warping window size of dtw for time series classification. In *Information Science, Signal Processing and their Applications (ISSPA), 2012 11th International Conference on*, pages 1272–1277. IEEE, 2012.
- [69] Stan Salvador and Philip Chan. Toward accurate dynamic time warping in linear time and space. *Intelligent Data Analysis*, 11(5):561–580, 2007.