



RECONHECIMENTO BIOMÉTRICO USANDO INFORMAÇÃO DA ÍRIS E DE CARACTERÍSTICAS PERIOCULARES

Edmundo Daniel Hoyle Delgado

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Antonio Petraglia

Rio de Janeiro
Outubro de 2013

RECONHECIMENTO BIOMÉTRICO USANDO INFORMAÇÃO DA ÍRIS E DE
CARACTERÍSTICAS PERIOculares

Edmundo Daniel Hoyle Delgado

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Antonio Petraglia, Ph.D.

Prof. Lisandro Lovisolo, D.Sc.

Dr. Gilson Alexandre Ostwald Pedro da Costa, D.Sc.

Prof. Jose Gabriel Rodriguez Carneiro Gomes, Ph.D.

Prof. Julio Cesar Boscher Torres, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
OUTUBRO DE 2013

Delgado, Edmundo Daniel Hoyle

Reconhecimento biométrico usando informação da íris e de características perioculares/Edmundo Daniel Hoyle Delgado. – Rio de Janeiro: UFRJ/COPPE, 2013.

XIII, 75 p.: il.; 29, 7cm.

Orientador: Antonio Petraglia

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2013.

Referências Bibliográficas: p. 69 – 75.

1. Biometria. 2. Reconhecimento. 3. Iris.
4. Periocular. 5. Wavelet. I. Petraglia, Antonio.
- II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*A meus pais Edmundo e
Carmen, a minha amada
Vanessa e a minha adorada Ana
Paula.*

Agradecimentos

Ao prof. Antonio Petraglia pela orientação e amizade que me deu desde o início, seu apoio foi fundamental para terminar meu trabalho. A família deBayser, pelos anos de convivência. Aos meus amigos da casa deBayser, foram muitos anos de amizade. Aos meus companheiros de estudo e amigos do Laboratório de Processamento Analógico e Digital de Sinais - PADS, não dou nomes para não cometer o erro de esquecer alguém.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

RECONHECIMENTO BIOMÉTRICO USANDO INFORMAÇÃO DA ÍRIS E DE CARACTERÍSTICAS PERIOculares

Edmundo Daniel Hoyle Delgado

Outubro/2013

Orientador: Antonio Petraglia

Programa: Engenharia Elétrica

Os sistemas biométricos para aplicações de elevada segurança de hoje devem atender a rigorosos requisitos de desempenho. O uso dos detalhes da íris, como informação biométrica para sistemas de segurança, é uma das formas mais seguras de garantir uma correta identificação. Uma desvantagem dessa técnica é que a íris é um alvo de dimensões relativamente pequenas, e conseqüentemente seus detalhes podem não ser capturados corretamente, comprometendo o desempenho do reconhecimento. Essa diminuição pode ser de certo modo compensada com a fusão de diferentes técnicas biométricas, o que é denominado como sistema biométrico multimodal. Neste trabalho é desenvolvido um método biométrico multimodal que usa informação da íris e da região periocular para melhorar a performance do reconhecimento. Também é desenvolvido um método para o processo de normalização da íris para torná-lo mais rápido, sem prejudicar significativamente o desempenho final do procedimento de identificação.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

BIOMETRIC RECOGNITION USING IRIS INFORMATION AND FEATURES
PERIOCLAR

Edmundo Daniel Hoyle Delgado

October/2013

Advisor: Antonio Petraglia

Department: Electrical Engineering

Modern biometric systems for high security applications must satisfy rigorous performance requirements. Biometric information of the iris details is one of the safest ways to guarantee a correct identification. One disadvantage of this approach is the fact that the iris is a small target, and its details might not be correctly captured, thereby decreasing its recognition performance. This decrease can be somewhat compensated by a combination of other biometric techniques, which is termed multimodal biometric system. This work developed a multimodal system that uses information from the iris and periocular regions to increase the recognition performance. Also proposed is a iris normalization process to make faster, without degrading significantly the identification procedure.

Sumário

| | |
|--|-------------|
| Lista de Figuras | x |
| Lista de Tabelas | xiii |
| 1 Introdução | 1 |
| 2 Segmentação da região da íris | 13 |
| 2.1 Localização dos círculos das bordas da íris nas imagens do banco UBIRIS | 14 |
| 2.1.1 Resultados | 17 |
| 2.2 Segmentação da íris em imagens capturadas com luz infravermelha . . | 17 |
| 2.2.1 Pupila | 19 |
| 2.2.2 Cílios | 21 |
| 2.2.3 Íris | 22 |
| 2.2.4 Pálpebras | 22 |
| 2.2.5 Resultados | 23 |
| 3 Normalização | 26 |
| 3.1 Método de normalização de Daugman | 26 |
| 3.2 Proposta de normalização da íris | 27 |
| 3.3 Comparação dos métodos | 30 |
| 3.3.1 Avaliação no reconhecimento | 31 |
| 3.3.2 Avaliação no tempo de processamento | 33 |
| 4 Identificação de indivíduos usando imagens capturadas sem coope- ração | 35 |
| 4.1 Sistema biometrico multimodal para imagens sem cooperação dos usuários | 36 |
| 4.1.1 Método de mapas de comparações | 37 |
| 4.1.2 Método usando a Wavelet 1-D | 40 |
| 4.1.3 Método usando Wavelet 2-D | 42 |
| 4.1.4 Método usando o <i>Local Binary Pattern</i> | 43 |

| | | |
|----------|---|-----------|
| 4.1.5 | Método usando <i>Scale-Invariant Feature Transform</i> | 44 |
| 4.1.6 | Fusão dos métodos | 47 |
| 4.2 | Resultado dos testes de desempenho | 48 |
| 5 | Identificação de indivíduos usando imagens capturadas com cooperação | 53 |
| 5.1 | Sistema biométrico multimodal para imagens capturadas com cooperação dos usuários | 56 |
| 5.1.1 | SIFT na região periocular | 57 |
| 5.1.2 | SIFT na imagem da íris normalizada | 59 |
| 5.1.3 | Fusão dos métodos | 62 |
| 5.2 | Resultados dos testes do desempenho | 63 |
| 6 | Conclusões e trabalhos futuros | 67 |
| 6.1 | Conclusões | 67 |
| 6.2 | Trabalhos futuros | 68 |
| | Referências Bibliográficas | 69 |

Lista de Figuras

| | | |
|------|--|----|
| 1.1 | Características biométricas. | 7 |
| 1.2 | Mudanças da região periocular no tempo. | 8 |
| 2.1 | Processo de captura de imagens do banco UBIRIS. | 14 |
| 2.2 | Imagens do banco UBIRIS. | 15 |
| 2.3 | Imagens do banco da UBIRIS com suas respectivas máscaras da região da íris. | 15 |
| 2.4 | Etapas da segmentação: (a) imagem original; (b) máscara da íris; (c) contorno da máscara; (d) círculo que representa a máscara; (e) imagem original em tons de cinza e realçada; (f) região de interesse; (g) bordas dentro da região de interesse; (h) círculos que representam a íris e a pupila. | 16 |
| 2.5 | Segmentação errada da pupila nas imagens do banco UBIRIS. | 17 |
| 2.6 | Imagens do banco CASIA versão <i>Lamp</i> | 18 |
| 2.7 | Imagens do banco CASIA versão <i>Thousand</i> | 18 |
| 2.8 | Etapas da segmentação da Pupila: (a) imagem original; (b) imagem realçada; (c) histograma da intensidade dos pixels numa determinada linha; (d) resultado da busca de pixels escuros em cada linha da imagem; (e) resultado de procurar pixels escuros em cada coluna da imagem; (f) interseção das imagens binárias; (g) aplicação de técnicas morfológicas; (h) bordas na região de interesse; (i) círculo encontrado após de aplicar a transformada de Hough. | 20 |
| 2.9 | Etapas da localização dos cílios: (a) região usada para a elaboração do histograma da intensidade dos pixels da imagem; (b) resultado da binarização; (c) resultado final depois de apagar pontos sem interesse. | 21 |
| 2.10 | Etapas da localização da borda externa da íris: (a) bordas encontradas após aplicar o filtro de Canny; (b) redução do espaço e do número de pontos de interesse; (c) borda da íris localizada após a aplicação da transformada de Hough. | 22 |

| | | |
|------|---|----|
| 2.11 | Etapas da localização das pálpebras: (a) delimitação da região de interesse; (b) bordas usadas para a localização das pálpebras; (c) pálpebras localizadas após a aplicação da transformada de Hough. | 23 |
| 2.12 | Segmentação da região da íris. | 23 |
| 2.13 | Imagens dos bancos CASIA nas quais não foi localizada a pupila. | 24 |
| 2.14 | Imagens dos bancos CASIA segmentadas com sucesso. | 25 |
| 2.15 | Imagens dos bancos CASIA com erros na segmentação. | 25 |
| 3.1 | Diferentes posições do olho e dilatações da pupila. | 27 |
| 3.2 | Método de normalização de Daugman. | 27 |
| 3.3 | Detalhes do método proposto usando círculos concêntricos. | 28 |
| 3.4 | Problema das pupilas deslocadas: (a) exemplo do uso dos círculos concêntricos numa pupila deslocada do centro da íris; (b) histograma do deslocamento da pupila do centro da íris. | 29 |
| 3.5 | Círculos não concêntricos usados para normalizar a íris. | 30 |
| 3.6 | Imagens da íris normalizada. | 30 |
| 3.7 | Valores da decidibilidade e do EER para cada teste na versão <i>Lamp</i> | 32 |
| 3.8 | Valores da decidibilidade e do EER para cada teste na versão <i>Thousand</i> | 32 |
| 3.9 | Redução do tempo do processo de normalização versus o número de pixels da íris normalizada. | 34 |
| 4.1 | Metodologia proposta. | 37 |
| 4.2 | Codificação da íris (<i>IrisCode</i>) [3]. | 38 |
| 4.3 | Mapas de comparação. | 38 |
| 4.4 | Imagens normalizadas. | 41 |
| 4.5 | Representações da wavelet e do zero-crossing. | 41 |
| 4.6 | Passos para extração de características da íris. | 44 |
| 4.7 | Procedimento da representação da imagem usando o SIFT. | 46 |
| 4.8 | Procedimento de comparação usando o SIFT. | 47 |
| 4.9 | Curvas ROC obtidas pela fusão e por cada método. | 50 |
| 4.10 | Curvas CMC obtidas pela fusão e por cada método. | 50 |
| 4.11 | Exemplo de aquisição de imagens de olhos do mesmo usuário. | 51 |
| 4.12 | Imagens do banco UBEAR (parte superior), e região em torno a orelha (parte inferior). | 52 |
| 5.1 | Curvas CMC da fusão dos métodos perioculares com cada método que utiliza a íris. | 55 |
| 5.2 | Curvas CMC da fusão do método 1-D Wavelet com cada método periocular. | 55 |
| 5.3 | Metodologia proposta para imagens capturadas com luz infravermelha. | 57 |

| | | |
|------|---|----|
| 5.4 | Descritores do SIFT mantidos por ficarem perto das bordas da imagem. | 58 |
| 5.5 | Imagens de olhos do mesmo usuário: os olhos têm tamanhos similares, não existe quase rotação entre eles, mas têm posições diferentes. . . . | 58 |
| 5.6 | Procedimento do SIFT em olhos iguais. | 59 |
| 5.7 | Procedimento do SIFT em olhos diferentes. | 59 |
| 5.8 | Imagens do mesmo usuário com diferentes dilatações da pupila. . . . | 60 |
| 5.9 | Procedimento de extração das características da íris normalizada usando o SIFT. | 60 |
| 5.10 | Comparação entre duas imagens do mesmo usuário usando o SIFT. . | 61 |
| 5.11 | Comparação entre duas imagens de usuários diferentes usando o SIFT. | 62 |
| 5.12 | Testes de desempenho utilizando a versão Lamp. | 64 |
| 5.13 | Testes de desempenho utilizando a versão Thounsand. | 65 |

Lista de Tabelas

| | | |
|-----|--|----|
| 1.1 | Pontos fortes e fracos de algumas características biométricas. | 4 |
| 3.1 | Tempo requerido para completar o processo de normalização da íris. . | 33 |
| 4.1 | Valores da performance do Reconhecimento. | 49 |
| 5.1 | Performance das fusões. | 54 |

Capítulo 1

Introdução

A segurança dos sistemas e serviços é um dos temas mais discutidos hoje em dia por causa de fraudes, falsificação de documentos, patentes e terrorismo. Isto motivou a investigação de sistemas de identificação pessoal baseada em características biométricas. Esses métodos têm a vantagem sobre os meios tradicionais de identificação por não exigirem a lembrança de senha e não poderem ser roubadas ou forjadas.

Uma das formas de identificação mais usadas é a aplicação de senhas. Por exemplo, o acesso a um site de banco requer que o usuário informe o número de sua agência, o número de sua conta e uma senha. Dependendo da operação a ser feita, outra senha pode ser requerida. Há também o uso de cartões com chips ou com dispositivos magnéticos que permitem a identificação de um indivíduo através de uma simples leitura. Este procedimento é comum, por exemplo, em crachás ou em lugares cujas portas só se abrem se o cartão lido tiver privilégios para tal.

Garantir sistemas e serviços seguros é um dos grandes problemas encontrados por governos, indústrias e organizações de maneira geral. Essa preocupação vai desde evitar fraudes e falsificações em documentos até, por exemplo, garantir segredos industriais envolvendo patentes. O uso de características biológicas para identificação se mostra como uma ideia viável, porque cada pessoa possui características biométricas diferentes das outras. Qualquer característica fisiológica ou comportamental humana pode ser usada como característica biométrica desde que ela satisfaça alguns requisitos básicos [1]:

- **Universalidade:** Toda a população (a ser autenticada) deve possuir a característica.
- **Unicidade:** Uma característica biométrica deve ser única para cada indivíduo.
- **Permanência:** A característica deve ser imutável. Na prática, existem alterações ocasionadas pelo envelhecimento, pela mudança das condições de saúde

ou mesmo emocionais das pessoas e por mudanças nas condições do ambiente de coleta.

- **Coleta:** A característica tem que ser passível de mensuração por meio de um dispositivo.
- **Aceitação:** A coleta da característica deve ser tolerada pelo indivíduo. Na prática existem preocupações com higiene, privacidade e questões culturais que diminuem a aceitação da coleta.

Um sistema biométrico típico pode ser descrito pelas seguintes etapas:

- **Aquisição da amostra biométrica:** Nesta etapa os dados da característica biométrica são adquiridos. A dificuldade deste processo é conseguir um equilíbrio na qualidade da amostra sem causar excesso de inconveniência para o usuário.
- **Extração de características:** Nesta etapa é produzida uma representação computacional do exemplar obtido, que chamaremos de atributos ou características extraídas.
- **Registro:** O perfil biométrico obtido, ou *template*, é armazenado para uma comparação posterior.
- **Comparação e decisão:** Na comparação, ou *matching*, é verificado o grau de similaridade entre as características extraídas do usuário e o perfil armazenado. O valor determinado é comparado com certo limiar, ou *threshold*, para tomar a decisão de aceitar ou rejeitar o usuário.

Em 1936 um oftalmologista chamado Frank Burch sugeriu que as características da textura da íris humana poderiam ser utilizadas como método de identificação pessoal. Essa teoria foi documentada por James Daggarts em 1949. Mas apenas em 1987 dois oftalmologistas, Aran Safir e Leonard Flom patentaram a idéia de identificar de forma automática um indivíduo através das características da íris [2]. John Daugman, pesquisador do Laboratório de Computação da Universidade de Cambridge (UK) desenvolveu com sucesso um algoritmo computacional capaz de realizar o reconhecimento de um indivíduo através das características de textura da íris [3]. Seu método, baseado na transformada wavelet e no filtro de Gabor, que foi patentado em 1993 e consistia de uma sequência de 256 bytes denominado *IrisCode*, é o mais conceituado sobre reconhecimento da íris.

Junto com o modelo de Daugman, os métodos propostos por Wildes [4], Boles [5, 6] e Ma [7, 8] são os mais mencionados na literatura. Os métodos de Wildes

[4] e Boles [5, 6], entretanto, têm determinadas limitações. O método do Wildes trabalha somente na modalidade de verificação, e o método de Boles não tem um bom desempenho no reconhecimento quando existe ocultação da íris (dita “occlusão”). Ma [7] propôs um método posteriormente melhorado [8] que usa a textura da íris.

Em outros trabalhos na literatura, Sanchez-Avila[9] e Sanchez-Reillo [10] deram continuidade ao trabalho de Boles desenvolvendo um sistema que utiliza a representação *zero-crossing* da transformada wavelet para se construir em templates da íris. A inovação em relação ao trabalho de Boles foi a introdução de técnicas baseadas em métricas de distância como a Euclidiana e a distância de Hamming para os processos de verificação e decisão [9], [10]. Monro [11] introduziu um método da codificação da íris baseado em diferenças dos coeficientes da transformada discreta do cosseno (DCT) das alterações angulares sobre as imagens normalizadas da íris. Roy [12] trabalhou em um esquema de seleção de características baseado no algoritmo genético de múltiplos objetivos (MOGA) para melhorar a exatidão do reconhecimento. Poursaberi [13] usou a distância média dos harmônicos e distância Hamming para determinar uma identificação correta. Noh [14] propôs um novo método para se representar as características da íris, baseado em *multiresolution independent component analysis* (M-ICA). ICA é um algoritmo não supervisionado usado para a redução de dimensionalidade que faz uso de estatísticas de ordens elevadas e o M-ICA é um novo método para a extração de características, introduzido em [14]. O autor apresentou comparações do método por ele proposto com técnicas baseadas em wavelets de Gabor, Haar e Daubechies. O discriminante de Fisher foi adotado como ferramenta de classificação. Yu [15] aplicou filtros multi-canais de Gabor em 2-D para capturar a textura da íris, extraiu os pontos que poderiam representar a textura local e usou a distância Euclideana para o reconhecimento das características da íris.

Muitas tecnologias biométricas além da íris têm sido propostas com base em características físicas, tais como impressões digitais, tom de voz, rosto, orelhas, mão e retina, cada um com seus pontos fortes e fracos [16]. Na Tabela 1 se encontra um resumo das características biométricas mais usadas. Nesse cenário os sistemas baseados na estrutura da íris vêm ganhando destaque em relação a outros métodos. A íris contém detalhes que a tornam umas das estruturas biométricas mais seguras para a identificação. Trata-se de um órgão interno que faz parte do globo ocular protegido pela córnea do olho, é colorida e sua função é controlar os níveis de luz, de forma semelhante ao comportamento do diafragma de uma câmera fotográfica. A pupila é a abertura para a entrada de luz que é controlada pela íris [17], que é formada no início da gravidez durante os três primeiros meses de gestação. Sua estrutura é completada aos oito meses e após esse tempo ocorrem algumas mudanças de textura. Aos dois ou três anos de idade ela deixa de mudar [18]. Por ser

| Sistema Biométrico | Pontos Fortes | Pontos Fracos |
|--------------------|---|--|
| Impressão Digital | <p>Pode proporcionar bastante precisão.</p> <p>A impressão digital pode ser colhida facilmente a baixo custo.</p> <p>Existem grandes bancos de dados de impressões digitais disponíveis.</p> | <p>A qualidade das impressões digitais varia enormemente dentro de uma população.</p> <p>Os sensores mais baratos podem ser comprovadamente fraudados.</p> |
| Rosto | <p>Existe larga aceitação pública para este identificador biométrico.</p> <p>Os sistemas de reconhecimento de face são os menos intrusivos.</p> | <p>Não fornece unicidade suficiente para identificação em larga escala.</p> <p>Facilidade de fraudar o sistema.</p> |
| Íris | <p>Atualmente a íris é considerada como a biometria mais precisa.</p> <p>Possui alto desempenho no processo de verificação.</p> <p>Para o processo de identificação, o desempenho é muito bom, com velocidade de comparação de 100.000 registros por segundo.</p> | <p>A íris não é um alvo fácil. É um alvo pequeno (1 cm) e tem que ser adquirido a uma distância não maior do que um metro.</p> <p>A maioria dos bancos de dados existentes foi criada para uso comercial e não está disponível publicamente.</p> |
| Mão | <p>A coleta das características é fácil e não intrusiva.</p> <p>Adequado para integração com outras biometrias, como impressão digital.</p> <p>Não relacionado a registros policiais e criminais.</p> | <p>O contato do usuário com uma superfície pode despertar preocupações públicas com higiene.</p> <p>Não fornece unicidade suficiente para identificação em larga escala.</p> |
| Assinatura | <p>Possui grande aceitação por parte do usuário.</p> <p>A assinatura dinâmica é bastante difícil de ser fraudada.</p> | <p>O custo dos dispositivos de aquisição é alto.</p> <p>Esta característica biométrica possui alta variabilidade. Existem, ainda, muitas pessoas com assinaturas inconsistentes.</p> |
| Voz | <p>É uma biometria usada instintivamente pelas pessoas para autenticação mútua.</p> <p>Sistemas com infraestrutura telefônica constituem o principal alvo do reconhecimento de voz.</p> <p>Esta tecnologia utiliza dispositivos baratos, e é facilmente desenvolvida.</p> | <p>Existem sistemas que podem ser treinados para imitar a voz de pessoas.</p> <p>O padrão de voz é bastante frágil, porque pode depender do estado de saúde do usuário, por exemplo.</p> <p>A qualidade do sinal de áudio é suscetível ao ruído do ambiente.</p> |

Tabela 1.1: Pontos fortes e fracos de algumas características biométricas.

claramente visível, sua captura é mais imediata que a da retina, que é dificultada pelo fato de que esta não é visível [19]. A desvantagem é que partes da imagem da íris são ocultas geralmente pelos cílios e pelas pálpebras [20]. Outra desvantagem corresponde à aquisição da imagem do olho. A qualidade desta será vital para o desempenho do reconhecimento, e pelas dimensões da íris o usuário tem que ficar próximo do dispositivo de captura sem se movimentar, para que a íris capturada tenha dimensões razoáveis e seus detalhes fiquem claros. É preferível que a captura seja com luz infravermelha, a fim de revelar até mesmo detalhes que não podem ser vistos apenas com luz visível [3]. O comprimento de onda considerado seguro pela Academia Americana de Oftalmologia está na faixa de 700 a 900 nanômetros [3].

Como um exemplo prático dos avanços da tecnologia de reconhecimento de íris motivados por interesses financeiros, o Cairo Amman Bank instalou na Jordania um sistema em 100 caixas eletrônicos de 80 filiais [21]. Em mais de um milhão de transações desde 2009 não ocorreu nenhuma operação fraudulenta. Em Buckinghamshire, na Inglaterra, o banco atualizou o sistema para a captura das duas íris com o objetivo de aumentar a sua precisão e manter a liderança no mercado, pois bancos concorrentes começaram a usar a tecnologia [21].

O processo baseado na identificação da íris pode ser dividido nas seguintes etapas:

Captura da imagem. Esta primeira etapa corresponde à aquisição da imagem do olho. A qualidade desta será vital para a performance das etapas seguintes. Como mencionado anteriormente, é preferível que a captura seja com luz infravermelha, a fim de revelar até mesmo detalhes que não podem ser vistos apenas com luz visível.

Segmentação e localização. Nesta etapa a pupila, a íris e as pálpebras são localizadas e segmentadas.

Normalização. Depois da íris ser segmentada é preciso compensar as variações de distância entre a câmera e o usuário, e as alterações do tamanho da pupila causadas por variações de luminosidade.

Representação. Já com a íris normalizada, têm que ser extraídas as características que serão usadas para ser representada.

Reconhecimento. Etapa final que corresponde ao método que será usado para distinguir entre duas ou mais representações da íris, e determinar se correspondem à mesma pessoa ou não.

Pesquisas podem ser focalizadas para produzir novos métodos, ou melhorar os existentes, para tornar o processo de reconhecimento mais eficiente em termos de tempo de processamento, desempenho ou ambos. Com referência à normalização

da íris, o método proposto por Daugman [3, 22] é o mais usado. A nossa pesquisa encontrou mais duas propostas diferentes. Na primeira, Min [23] utiliza uma área quadrada dentro da circunferência da íris, e usa a textura da íris para preencher a região da pupila. Na segunda, Yuan [24] usa uma transformação não-linear baseada no conceito do desgaste mínimo da malha (*'minimum-wear-and-tear' meshwork*), que foi simplificado para poder ser usado no reconhecimento. Este modelo é empregado para mostrar as propriedades não lineares da deformação da íris quando a pupila sofre mudanças de tamanho, como explicado em [25]. O problema principal do método de Yuan é o fato de considerar os círculos que representam a pupila e a íris como concêntricos, quando na realidade isso nem sempre acontece. No Capítulo 3 consideraremos com mais detalhes o problema da não concentricidade da pupila com respeito à íris.

Os sistemas biométricos para aplicações de elevada segurança devem atender a rigorosos requisitos de desempenho. A fusão de múltiplas técnicas ajuda a biometria a minimizar as taxas de erro do sistema. Sistemas biométricos com base em uma única fonte de informação são chamados de sistemas unimodais. Embora alguns desses sistemas [26] sejam consideravelmente bons em termos de confiabilidade e precisão, eles geralmente sofrem de problemas de registro, devido ao fato de que características biométricas não são universais [27].

Uma forma de evitar esses problemas consiste na utilização de métodos biométricos multimodais, que combinam informações de diversas características biométricas para melhorar a performance em termos da precisão no reconhecimento dos indivíduos. Atualmente existem algumas variações dos sistemas biométricos com respeito aos sistemas biométricos clássicos:

- **Multialgoritmos:** Usam características de uma única fonte biométrica que é processada através de dois ou mais algoritmos. Os resultados produzidos pelos algoritmos são combinados para se obter um resultado de reconhecimento único. Em [28] foi mostrado um incremento no desempenho do reconhecimento 2D de rosto combinando diferentes resultados de sistemas comerciais.
- **Multiamostras:** Sistemas que usam diferentes amostras da mesma fonte biométrica, que são processadas por um único algoritmo. Os resultados de cada amostra são fusionados para obter a decisão final. A vantagem desta estratégia é que o uso de várias amostras pode superar o fraco desempenho devido a uma amostra que tem propriedades não ideais. O problema é que requerem maior cooperação do usuário para completar as amostras necessárias para completar o processo de identificação.
- **Multimodal:** O termo multimodal é usado quando são combinadas duas



Figura 1.1: Características biométricas.

ou mais características biométricas de uma mesma pessoa, ou duas ou mais propriedades diferentes da mesma característica biométrica.

Na Fig. 1.1 é possível observar algumas características biométricas mais conhecidas do indivíduo. Em sistemas biométricos de tipo multimodal são usadas majoritariamente as características que precisam de diferentes sensores para extrair as amostras, como ao usar um sensor para extrair as características da impressão digital e outro para as do rosto. Esses tipos de sistemas elevam o custo do equipamento e requerem maior cooperação do usuário.

Além das características biométricas mencionadas anteriormente, existem uma outra característica que está atraindo pesquisadores para uma área relativamente nova, que é a biometria periocular. A biometria periocular refere-se à identificação de indivíduos usando a região em torno do olho que contém as pálpebras, cílios, e parte das sobrancelhas [29]. Comparado com as impressões digitais, rosto, íris ou outros sistemas biométricos conhecidos, o reconhecimento usando informação periocular ainda não foi bem investigado. Os primeiros estudos de viabilidade foram realizados por Park [30], e ampliados em [31].

A região periocular oferece vantagens com respeito ao reconhecimento facial, porque é menos afetada pelas variações de expressão, efeitos do envelhecimento ou

do cabelo facial [32]. Na Fig. 1.2 podem ser observadas imagens da mesma pessoa ao longo do tempo, com suas respectivas regiões perioculares. É possível perceber que as mudanças na região periocular são menos notórias do que as mudanças no rosto todo. Em [33] foi mostrado que é possível atingir mais de 90% de exatidão para determinar o gênero e a raça de um indivíduo usando somente a informação periocular.



Figura 1.2: Mudanças da região periocular no tempo.

Uma característica que pode ser aproveitada da região periocular é a sua localização em torno do olho. Esta localização faz com que o tamanho da íris não fique tão reduzido como no caso em que é capturado o rosto do usuário. Portanto, os detalhes da íris podem revelar informações adicionais na imagem capturada da região periocular, do que da imagem capturada do rosto todo. A fusão das características da íris e da região periocular forjam a base para a criação de um sistema biométrico multimodal, que além do objetivo de melhorar a performance do reconhecimento com respeito ao uso das características separadamente não eleva o custo em termos de quantidade e diversidade de sensores.

Portanto o objetivo nesta pesquisa de tese foi desenvolver um método biométrico multimodal, que aproveite as características da íris em conjunto com as características da região periocular. Como início de nossa pesquisa participamos do *Noisy Iris Challenge Evaluation - Part 2* (NICE.II) [34], uma competição que teve como objetivo a avaliação de métodos biométricos na identificação de pessoas. Para isso foram disponibilizadas 1.000 imagens do banco UBIRIS.v2 [35], para serem utilizadas como conjunto de testes dos métodos a serem criados para uma identificação correta. Para cada uma das imagens disponibilizadas, tinha-se uma imagem binária indicando a localização da parte da íris que não foi obstruída pelas pálpebras, cílios ou reflexos nas lentes dos óculos dos usuários.

As imagens do banco UBIRIS.v2 foram capturadas no comprimento de onda visível e simularam um sistema de captura de imagens da íris, sem a cooperação dos usuários. Em outras palavras, os usuários não eram obrigados a fixarem a mi-

rada em direção à câmera enquanto o sistema fazia a captura da imagem. A zona da captura das imagens ficava focalizada na íris do olho, mas a câmera chegava a adquirir a região periocular. Portanto as imagens possibilitaram a implementação de um sistema de reconhecimento biométrico multimodal. Para esta implementação foram utilizados três métodos que usam as características da íris em conjunto com dois métodos que aproveitam as características perioculares, para realizar uma identificação correta.

O *Scale-Invariant Feature Transform* (SIFT) [36] e o *Local Binary Pattern* (LBP) [37] foram usados separadamente para desenvolver os dois métodos que utilizam as características perioculares. Com respeito aos métodos que utilizam a informação da íris, o primeiro método *Comparison Maps* (Mapas de Comparações) [38] é uma extensão do método de Daugman, que analisa a representação proposta em [3, 22] no domínio espacial e na frequência. O segundo e o terceiro métodos que utilizam a informação da íris são uma extensão do método de Boles, sendo que a diferença entre eles é o tipo de wavelet utilizada. Esta extensão do método de Boles foi desenvolvido em nossa pesquisa realizada no mestrado [39], e usada em diferentes trabalhos publicados [40–44].

O sistema biométrico multimodal proposto que funde os métodos relatados no parágrafo anterior foi testado com as imagens fornecidas pelos organizadores da competição. Os testes foram realizados usando diferentes medidas de avaliação para determinar seu desempenho na identificação correta dos usuários. Em cada avaliação, o método proposto teve sempre o melhor desempenho ao ser comparado a cada método individualmente. Além disso, foram criadas diferentes fusões com os métodos individuais, que também foram avaliadas. Mas o sistema proposto usando todos os métodos apresentou o melhor desempenho. Essas fusões nos permitiu apreciar quais métodos favorecem em maior grau ou menor grau o desempenho do reconhecimento quando são fusionados. O algoritmo do método proposto usando os cinco métodos foi enviado para sua avaliação por parte dos juízes da competição. O método conseguiu a terceira melhor avaliação no desempenho, entre os métodos dos quase setenta pesquisadores de diferentes países envolvidos nesta competição. O primeiro lugar [45] foi obtido pela equipe da *Chinese Academy of Sciences Institute of Automation* (CASIA), mostrando a qualidade dos participantes nesta competição. Devido às características das imagens usadas, como mudanças fortes de pose e escala, fica em evidência que nossa proposta é um aporte interessante para a criação de um sistema biométrico multimodal. O método proposto foi publicado posteriormente em [43].

Como foi explicado anteriormente, as imagens do UBIRIS.v2 simulam um sistema onde os usuários não cooperam para a aquisição da mostra biométrica, neste caso o olho junto com a região periocular. Mas na maioria dos sistemas biométri-

cos usados, como por exemplo aqueles para permitir o ingresso num determinado local, o usuário é exigido a fornecer certo grau de cooperação. Para simular esses sistemas e dar continuidade à nossa pesquisa, foram usadas as imagens do banco da CASIA [46]. As imagens do banco da CASIA ao invés das imagens do UBIRIS.v2, foram capturadas à mesma distância da câmera, na qual os usuários fixavam a mirada. Esta característica permite simular em certo grau um sistema biométrico que exija certa cooperação dos usuários. Para simular situações onde existem problemas de oclusão foram escolhidas duas versões diferentes do banco CASIA. A primeira versão (*Lamp*) tem como característica principal a oclusão da íris pelos cílios ou as pálpebras, e as variações na dilatação e contração da pupila. A segunda versão (*Thousand*) tem como principal característica o uso de óculos por parte dos usuários no momento da captura, e reflexos de luz que têm lugar nas lentes. Somando as imagens das duas versões a serem usadas, chegamos a ter mais de 30.000 imagens para realizar os testes necessários. O banco CASIA não fornece imagens binárias com a localização da íris, por isso foi necessário desenvolver métodos que cumpram esse objetivo.

Uma nova proposta para um sistema biométrico multimodal foi desenvolvida, com base nos comportamentos dos métodos usados na primeira proposta, e as características encontradas nas imagens que são capturadas com cooperação dos usuários. O objetivo nesta parte da pesquisa foi fazer com que a fusão de uma menor quantidade de métodos mantenha a mesma proporção de ganho no reconhecimento que foi obtida na primeira proposta. Esta proporção se refere ao aumento da fusão com respeito ao método individual que apresente o melhor desempenho. Para isso foram usados três métodos de identificação biométricos, sendo que dois deles usam a informação da íris e o terceiro utiliza a informação periocular. Nesta nova proposta, para realizar a identificação usando a região periocular, o SIFT foi escolhido ao invés do LBP. A escolha foi devido a que o SIFT mostrou um maior aporte no desempenho do reconhecimento quando é fusionado com os métodos que utilizam a informação da íris. Para realizar a identificação usando a informação da íris, o primeiro método usado foi a extensão do método de Boles, mas utilizando a wavelet que obteve o melhor desempenho com respeito a todos os métodos individuais da proposta anterior. Para o segundo método que usa a informação da íris, foi desenvolvido um método que emprega o SIFT na imagem normalizada da íris, para o reconhecimento dos usuários.

Este novo sistema biométrico multimodal também obteve um aumento do desempenho com respeito a cada método individual usado. A taxa do aumento foi quase a mesma que a da primeira proposta do sistema multimodal descrita anteriormente. A vantagem foi no tempo de processamento, que teve uma redução significativa de 50% no tempo total usado para a identificação.

Nesta pesquisa tese também foi estudada a etapa da normalização da íris, que segundo [3] e [8], a segmentação, a normalização e a representação são as etapas mais demoradas. O método usado majoritariamente para a normalização da íris, é o método que Daugman propôs em [3] para esta etapa. Nós propusemos um outro método para normalizar a íris usando círculos não concêntricos, que foi apresentada em [44]. Esta técnica permite diminuir em até 98% o tempo de processamento sem comprometer significativamente a performance do reconhecimento, quando comparada com a normalização proposta por Daugman. A diminuição do tempo vai depender das dimensões nas quais será normalizada a íris. Métodos de reconhecimento que usam a normalização proposta por Daugman frequentemente usam diferentes dimensões para normalizar a íris como em [8, 11, 38, 41].

Se focalizamos em sistemas biométricos multiamostras, onde são analisadas mais de uma imagem e usando um só algoritmo, o emprego de nossa proposta pode ser uma opção vantajosa. Ela poderia permitir o uso de mais amostras no mesmo intervalo de tempo, devido ao período reduzido para cada normalização da íris. Desta maneira seria possível melhorar o desempenho do sistema, ao ter uma maior quantidade de amostras para analisar.

Outro fator a ser levado em conta, é com respeito aos sistemas multimodais que usam a íris e outras características biométricas. Nestes sistemas a vantagem da diminuição do tempo na etapa da normalização, pode chegar a ser descartada devido ao tempo utilizado pelos demais métodos implementados. Por exemplo empregando nossa proposta de normalização da íris, a fusão dos métodos usado para as imagens capturadas sem cooperação dos usuários, produziu uma diminuição de 10% no tempo de processamento. Na proposta usada para imagens com cooperação dos usuários foi obtida um diminuição do tempo de 27%.

Um outro cenário onde pode ser válido o uso de nossa proposta é na etapa de teste dos algoritmos. Nesta etapa milhares de imagens são usadas repetitivamente para determinar o método e os parâmetros que apresentem o melhor desempenho no reconhecimento. Portanto, na etapa dos testes pode ser usada a normalização da íris proposta para diminuir o tempo de processamento, e para a implementação final do sistema de reconhecimento pode ser usada a normalização proposta por Daugman. Este procedimento pode ser realizado, com a garantia de que o desempenho do reconhecimento do sistema não vai sofrer degradação.

Para descrever detalhadamente as contribuições realizadas nesta pesquisa e resumidas nos parágrafos anteriores, os próximos capítulos da presente Tese foram organizados da seguinte maneira:

- O Capítulo 2 descreve os métodos usados para a segmentação da pupila e da íris, e para a detecção das pálpebras das imagens do banco CASIA, e para a localização das bordas interna e externa da íris nas imagens do UBIRIS.v2;

- O Capítulo 3 descreve os procedimentos de normalização da íris proposta por Daugman, e a proposta nesta pesquisa. São realizados testes que demonstram as vantagens da técnica nesta tese;
- O Capítulo 4 descreve a proposta para um sistema reconhecimento biométrico multimodal sem cooperação por parte dos usuários. São considerados os resultados dos testes, o desempenho no reconhecimento e o tempo de processamento.
- O Capítulo 5 relata a proposta para um sistema de reconhecimento biométrico multimodal com cooperação por parte dos usuários. São mostrados os benefícios da redução dos métodos em termos de eficiência de reconhecimento e tempo de processamento;
- O Capítulo 6 apresenta as conclusões desta pesquisa e sugestões de trabalhos futuros.

Capítulo 2

Segmentação da região da íris

A segmentação é a etapa responsável pela determinação da região da íris presente em uma imagem. Esta região, em forma de coroa circular, é comumente aproximada por dois círculos: um para a fronteira externa da íris-esclerótica (o tecido branco do olho) e outra para a borda interna da íris-pupila. Entretanto, apesar desta modelagem, nem sempre é possível assumir que os dois círculos são concêntricos. Pálpebras e cílios normalmente produzem oclusão nas partes superior e inferior da íris, e há também reflexões especulares e sombras que podem corromper sua textura. Uma técnica de segmentação bem sucedida deve localizar e tratar esses aspectos.

Como foi explicado na introdução, as imagens do banco da UBIRIS.v2 [35] que foram empregadas nesta pesquisa, tinham para cada imagem do banco um arquivo binário contendo a máscara da íris segmentada. Mas alguns dos métodos de reconhecimento utilizados, além da segmentação da íris, precisam também círculos que representam as bordas interna e externa da íris. Também foi dito, que o banco da CASIA não disponibiliza nenhum tipo de arquivo adicional.

Neste capítulo será usada a transformada de Hough para localizar círculos e parábolas. A matriz de acumulação da transformada de Hough para os círculos terá três parâmetros que representarão as coordenadas do centro e o raio de todos os círculos possíveis. Para localizar as parábolas, os parâmetros da matriz de acumulação da transformada serão as coordenadas do vértice e a distância do vértice ao foco da parábola de todas as possíveis parábolas. A posição do maior valor da matriz de acumulação indicará os parâmetros do círculo ou parábola localizada.

Este capítulo está dividido em duas seções. Na primeira é detalhado o procedimento usado para localizar os círculos que representem as bordas da íris em imagens do banco UBIRIS.v2. Na segunda seção onde serão usadas as imagens do banco CASIA [46], é explicado o procedimento para segmentar a região da íris e obter os círculos que representam as bordas da íris.

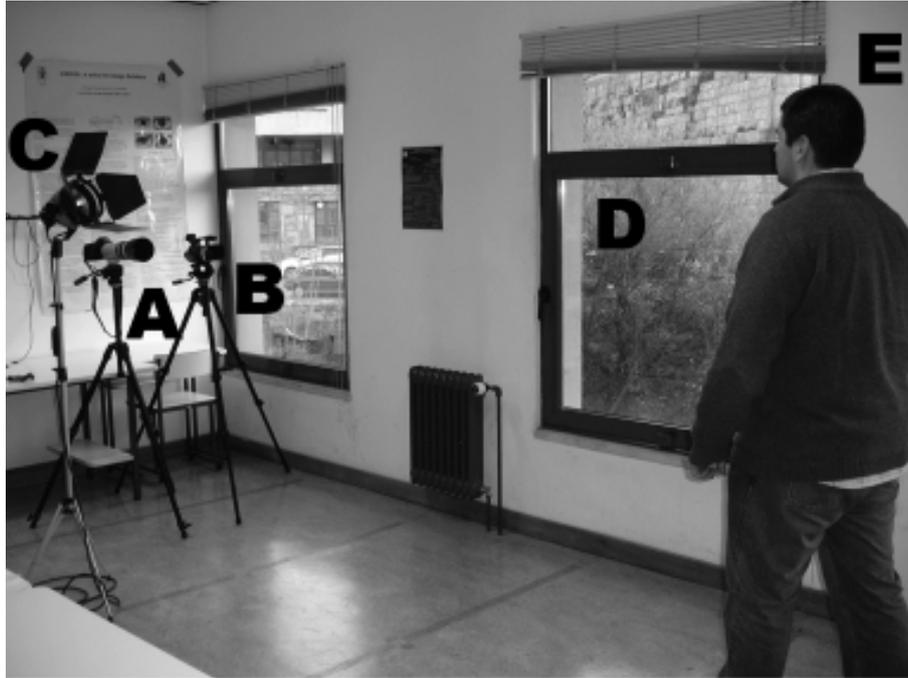


Figura 2.1: Processo de captura de imagens do banco UBIRIS.

2.1 Localização dos círculos das bordas da íris nas imagens do banco UBIRIS

O banco UBIRIS.v2 contém imagens com o propósito de permitir a avaliação da viabilidade do reconhecimento da íris, usando imagens capturadas no comprimento de onda visível e sem a cooperação dos usuários no momento da captura da imagem. Durante o processo de captura os usuários foram solicitados a caminhar lentamente olhando na direção de alvos em diferentes posições, como mostrado na Fig. 2.1 onde os alvos estão representados pelas letras A, B, C, D, e E na imagem. As capturas foram realizadas entre quatro e oito metros de distância entre o usuário e a câmera. O banco contém uma diversidade muito rica de condições não ideais (ver Fig. 2.2), como a captura das imagens em diferentes poses, uso de óculos, reflexos localizados na lentes dos óculos, entre outras.

Como foi explicado no capítulo anterior, recebemos 1.000 imagens do banco como conjunto de teste para a criação de um método biométrico para a identificação correta dos usuários. Para cada imagem dos olhos, foram disponibilizados arquivos que representam as máscaras da região da íris em imagens em preto (valor 0) e branco (valor 1), onde o valor 1 representa parte da região da íris, e o valor 0 representa qualquer outra região, como mostrado na Fig. 2.3.

Entretanto, os métodos empregados neste trabalho, que utilizam as características da íris, precisam que a íris esteja normalizada. O processo de normalização que vai ser explicado no capítulo seguinte, requer a localização dos círculos que

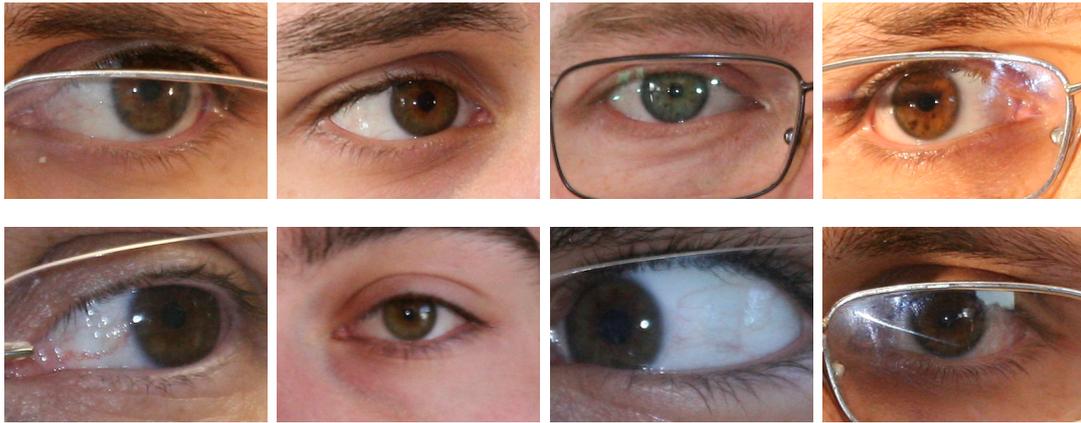


Figura 2.2: Imagens do banco UBIRIS.

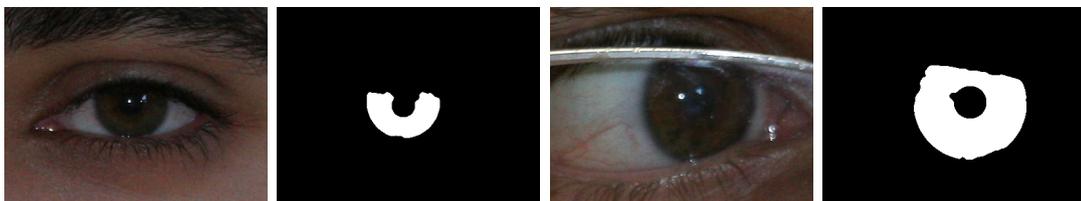


Figura 2.3: Imagens do banco da UBIRIS com suas respectivas máscaras da região da íris.

representem os bordas interna (pupila) e externa da íris.

O procedimento utilizado para determinar os círculos que representem as bordas interna e externa da íris mostradas na Fig. 2.4(h) é descrito abaixo:

- Na máscara da íris (Fig. 2.4(b)), para cada pixel com valor 1, são somados seus 8 vizinhos. Se o resultado é menor, indica que o pixel não pertence a uma borda e é apagado. Este procedimento fará que dois segmentos de pixels com valor 1 representando as bordas interna e externa da máscara sejam mantidos. O segmento com a maior quantidade de pixels e que representa a borda externa da máscara é conservado (Fig. 2.4(c)), ou outro é deletado.
- Em seguida, fazendo uso da transformada de Hough [47] será determinado o círculo cuja circunferência se superponha na maior quantidade de pixels que representam a borda da máscara (Fig. 2.4(c)). A borda externa da íris será representada por esse círculo, como mostrado em (Fig. 2.4(d)).
- Localizada a borda externa da íris, a imagem é convertida para tons de cinza e realçada (Fig. 2.4(e)). A imagem foi realçada utilizando o método da equalização do histograma das intensidades dos pixels da imagem.
- Para localizar o círculo da borda da pupila, o espaço de busca foi reduzido para uma região circular com centro no círculo que representa a borda externa

da íris, e com um raio 25% menor que o raio do mesmo círculo (Fig. 2.4(f)). O valor foi determinado pela pouca dilatação da pupila observada nas imagens do banco.

- No próximo passo é usado o operador de Canny [48] para extrair as bordas da imagem, e mantidas somente as bordas que estejam dentro da região circular descrita no item anterior, como pode ser observado em (Fig. 2.4(g)).
- Finalmente, é usada a transformada de Hough novamente para determinar o círculo que represente a borda interna da íris. O círculo é determinado por aquele cuja circunferência se superponha na maior quantidade de pixels que representam as bordas da imagem em (Fig. 2.4(g)). Na Fig. 2.4(h) são mostrados os círculos que representam as bordas da íris.

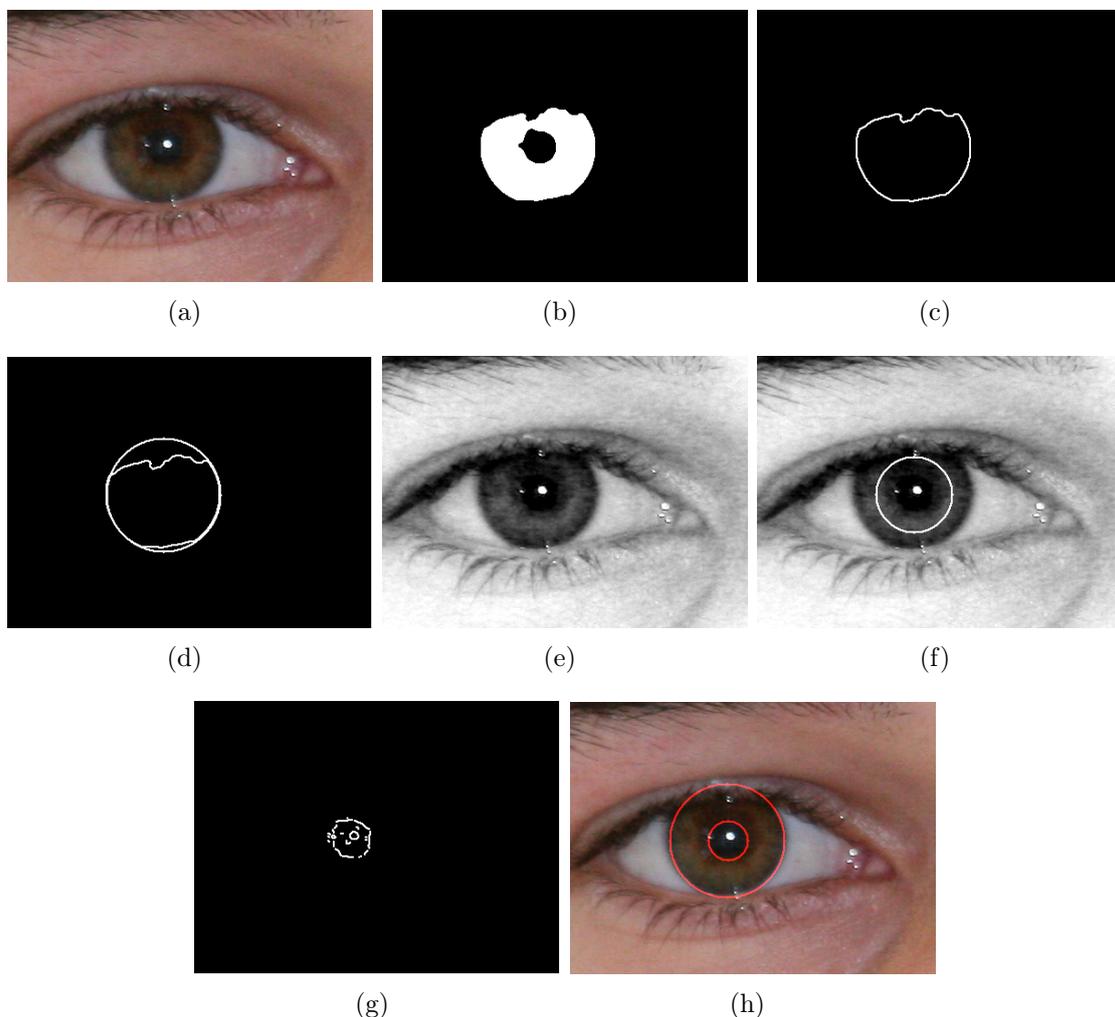


Figura 2.4: Etapas da segmentação: (a) imagem original; (b) máscara da íris; (c) contorno da máscara; (d) círculo que representa a máscara; (e) imagem original em tons de cinza e realçada; (f) região de interesse; (g) bordas dentro da região de interesse; (h) círculos que representam a íris e a pupila.

2.1.1 Resultados

Para verificar o desempenho do algoritmo para a localização dos círculos que representam as bordas da íris, foram empregadas 500 imagens do banco. Os resultados da localização dos círculos que representam a borda externa da íris não mostraram erros. Com respeito à borda da pupila, o algoritmo apresentou alguns problemas na localização. O problema foi devido às condições de pouca iluminação que não permitiu uma extração correta das bordas da pupila. Na Fig. 2.5 são mostradas imagens nas quais houve existiu erros da segmentação da pupila.

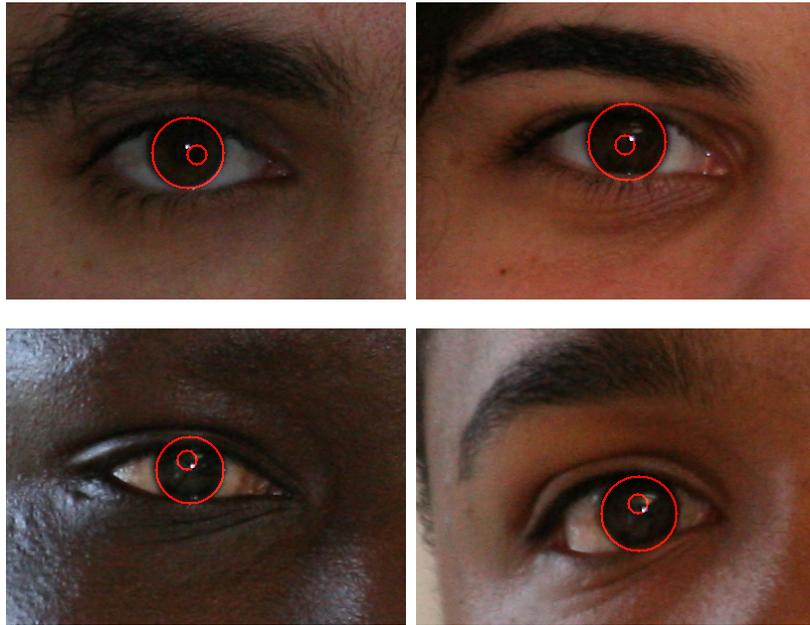


Figura 2.5: Segmentação errada da pupila nas imagens do banco UBIRIS.

2.2 Segmentação da íris em imagens capturadas com luz infravermelha

Nesta seção duas versões do banco CASIA que apresentam características diferentes serão usadas. A versão *Lamp* contém imagens que apresentam fortes deformações na textura da íris devido às variações de luminosidade que fazem a pupila se expandir ou contrair, além de ocultação da íris devido às pálpebras e cílios. A versão *Thousand* contém imagens que foram capturadas de usuários com óculos e apresentam reflexos especulares. As Figs. 2.6 e 2.7 apresentam exemplos das imagens do banco CASIA nas versões *Lamp* e *Thousand*, respectivamente.

A segmentação utilizada foi baseada no trabalho realizado no mestrado [39] e publicado posteriormente em [42], no qual a pupila e a íris foram modeladas como

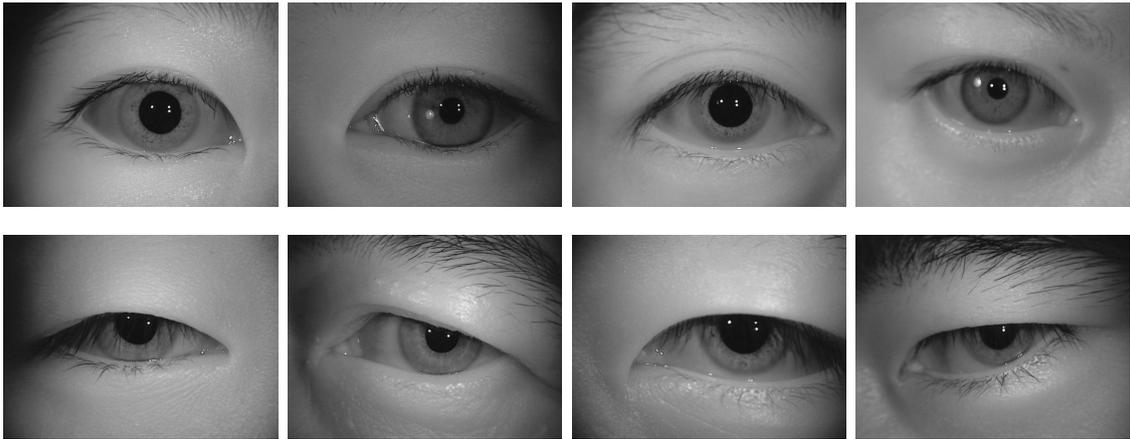


Figura 2.6: Imagens do banco CASIA versão *Lamp*.

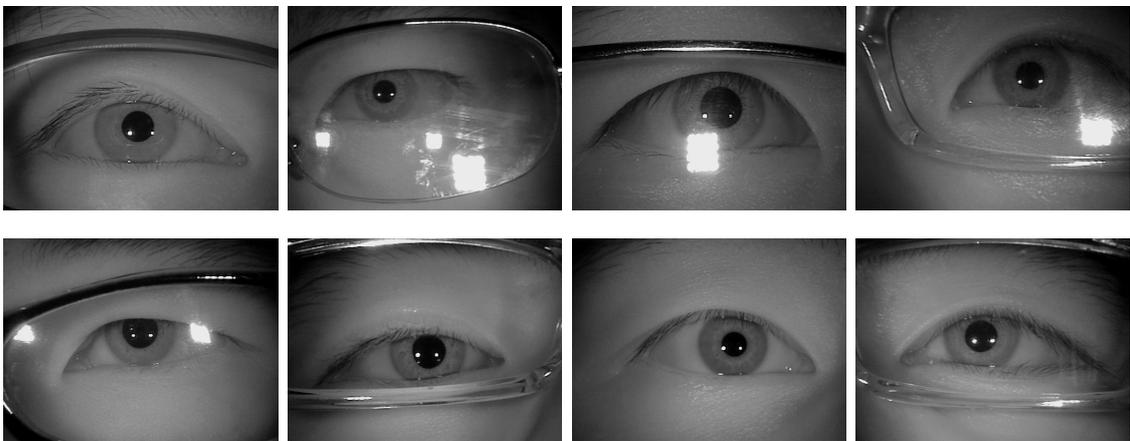


Figura 2.7: Imagens do banco CASIA versão *Thousand*.

dois círculos, e as pálpebras (superior e inferior) foram modeladas por duas parábolas localizadas nas imagens da íris normalizadas. Embora essa técnica tenha obtido bom desempenho na segmentação da íris, foram feitas duas modificações importantes nesta pesquisa:

- A primeira modificação foi evitar a dependência que o método tinha com relação aos LEDs infravermelhos. O método era baseado na localização dos LEDs refletidos na pupila. Essa aproximação requeria *a priori* o conhecimento do número de LEDs do sistema, e o algoritmo falhava quando os LEDs eram refletidos fora da pupila.
- O segundo problema encontrado se refere à etapa em que as pálpebras são localizadas. O método localizava as pálpebras na imagem da íris normalizada. Entretanto, para o método de reconhecimento que utiliza região periocular empregado nesta pesquisa, é necessário a localização na imagem capturada pela câmera.

As etapas referentes à segmentação da íris são apresentadas a seguir.

2.2.1 Pupila

A pupila é uma região rodeada pela íris escura e circular, que pode se dilatar ou contrair dependendo da intensidade da luz do ambiente. A busca por uma região escura e circular nem sempre é uma opção adequada, pelo fato de que se pode confundir com outras regiões (por exemplo acumulação dos cílios numa determinada região), ou parte da pupila poder estar oculta devido à superposição das pálpebras, descaracterizando a forma circular. Devido ao fato da região da pupila ser escura, propomos procurar os pixels mais escuros para cada linha ou coluna da imagem, para depois usar a interseção dos resultados e minimizar o número de regiões possíveis de conter a pupila.

Para localizar a pupila, primeiro a imagem é realçada (Fig. 2.8(b)) empregando a equalização do histograma das intensidades dos pixels da imagem (esta imagem será usada em outras etapas da segmentação da íris). Depois procuramos em cada linha e coluna da imagem os pixels escuros. O valor que vai definir o limiar máximo para que o pixel seja considerado escuro numa linha ou coluna, será o valor do primeiro mínimo local do histograma (Fig. 2.8(c)) criado a partir dos valores da intensidade dos pixels na determina da linha ou coluna, respectivamente. Pode acontecer que numa determinada linha ou coluna os valores das intensidades dos pixels sejam altos (muito claros), e por consequência, produzir um falso limiar para determinar os pixels escuros. Para evitar esse caso, determinamos experimentalmente que o primeiro mínimo global não deve exceder 0.6 na escala de 0 ao 1. Como resultado do passo anterior, temos duas imagens binárias (por clareza, pontos brancos são indicados para os pixels escuros), que representa a procura no sentido horizontal (Fig. 2.8(d)) (linhas) e no sentido vertical (Fig. 2.8(e)) (colunas) . O resultado da interseção das duas imagens binárias descritas anteriormente é usado para reduzir o espaço de localização da pupila (Fig. 2.8(f)).

Nos bancos de CASIA usados, foi possível observar que a pupila não fica próximo das bordas da imagem capturada. Esta característica, nos permitiu eliminar segmentos que contenham pixels localizados na borda da imagem capturada ou próximo dela. Foi determinado experimentalmente que uma distância não maior do que 40 pixels, é suficiente para eliminar segmentos perto da borda sem comprometer a localização da pupila. Utilizando técnicas de morfologia de erosão e depois dilatação, pequenos segmentos são apagados. Nos segmentos restantes é calculada a excentricidade em cada um deles, onde valor 0 indica um círculo perfeito. O segmento com o menor valor será mantido (Fig. 2.8(g)). Depois, o operador de Canny é aplicado na imagem realçada do olho, e somente são mantidos os pontos que estão localizados na

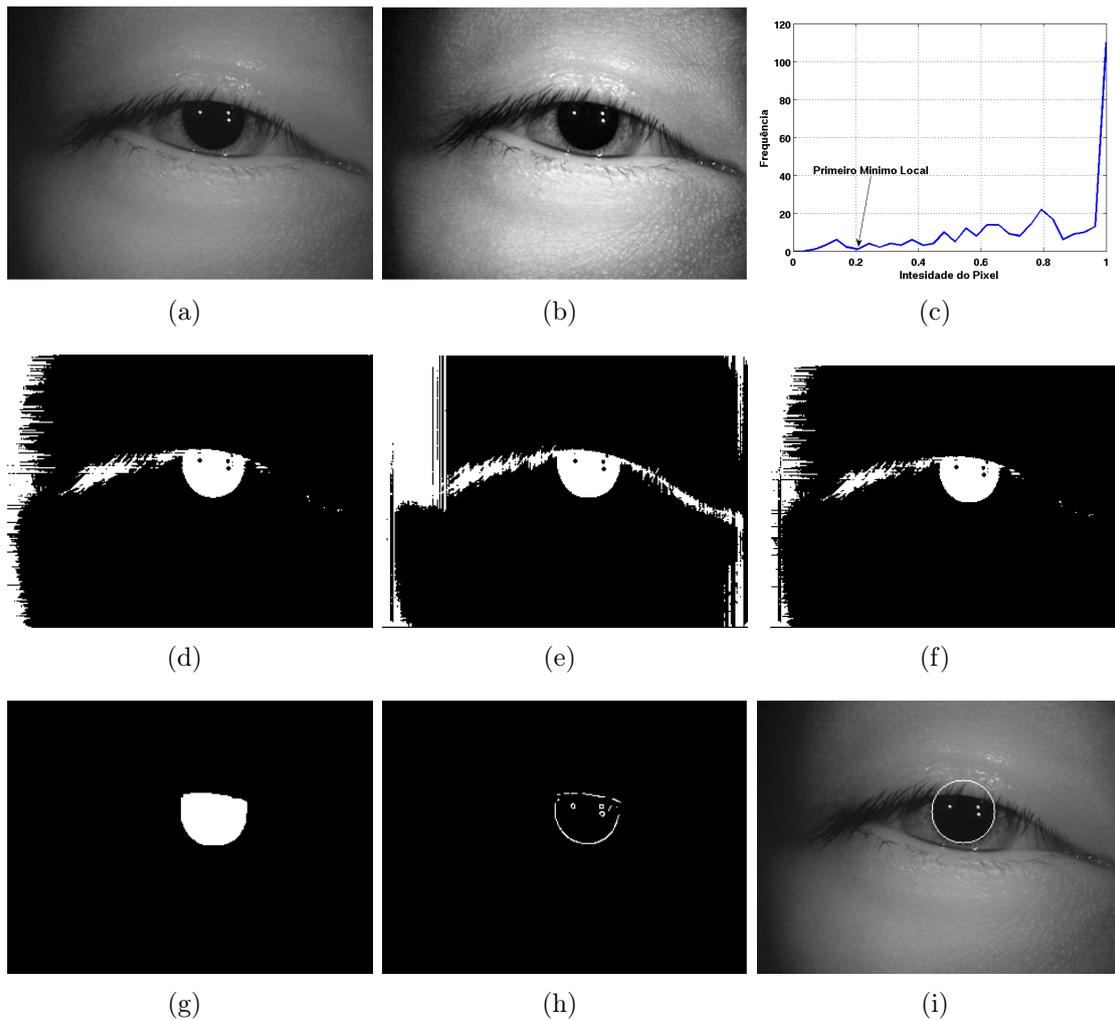


Figura 2.8: Etapas da segmentação da Pupila: (a) imagem original; (b) imagem realçada; (c) histograma da intensidade dos pixels numa determinada linha; (d) resultado da busca de pixels escuros em cada linha da imagem; (e) resultado de procurar pixels escuros em cada coluna da imagem; (f) interseção das imagens binárias; (g) aplicação de técnicas morfológicas; (h) bordas na região de interesse; (i) círculo encontrado após de aplicar a transformada de Hough.

região obtida no passo anterior (Fig. 2.8(h)). A transformada de Hough é aplicada nas bordas resultantes para obter o círculo que represente a pupila.

Para determinar se a pupila foi corretamente localizada são realizados dois testes:

- A primeiro determina a quantidade da área que corresponde aos pixels escuros com respeito à região representada pelo círculo que determina a borda da pupila. Se a área for menor do que a metade da área total do círculo, a localização não é aceita e o algoritmo é interrompido. A margem foi estabelecida devido a que a pálpebra pode obstruir parte da pupila, fazendo com que região escura do círculo não preencha a totalidade dela.
- Em seguida utilizam-se os pontos das bordas situadas no interior da região da

pupila, e calcula-se a razão entre o números de pontos que se interceptam com a circunferência da pupila e o número total de pontos. Se a razão for maior que 0.5 a localização é aceita. O valor foi determinado porque podem existir bordas que não representam a pupila, e nossos testes determinaram que o valor foi suficiente para garantir uma localização correta da pupila.

Além de evitar uma falsa localização da pupila, o teste acima evita a aceitação de imagens com uma íris quase oculta pelas pálpebras.

2.2.2 Cílios

Antes de proceder à busca da borda externa da íris, os cílios são localizados. O procedimento, além de detectar a oclusão causada pelos cílios, ajuda a descartar bordas falsas na etapa de localização da borda externa da íris. Nesta etapa também são localizadas sombras que aparecem frequentemente na pálpebra superior.

Notadamente, nas imagens do banco CASIA os cílios possuem uma tonalidade mais escura em relação à tonalidade da região da íris. Isso pode ser devido a que o banco de imagens está conformando por pessoas de origem asiática, que em sua maioria tem cílios escuros. Assim, usando a imagem já realçada na etapa anterior criamos um histograma da intensidade dos pixels, mas empregando os valores dos pixels da região delimitados pelo círculo da pupila e pelo círculo criado tomando como referência o centro da pupila e um raio 50% maior do que o raio da pupila (Fig. 2.9(a)).

O primeiro mínimo local do histograma determina o maior valor possível que podem ter os pixels que representam os cílios. Finalmente, fazendo uso de técnicas de morfologia de erosão e depois dilatação são eliminados pequenas formas isoladas, porque estas podem representar detalhes da íris. Na Fig. 2.9 são mostrados os passos para localizar os cílios.

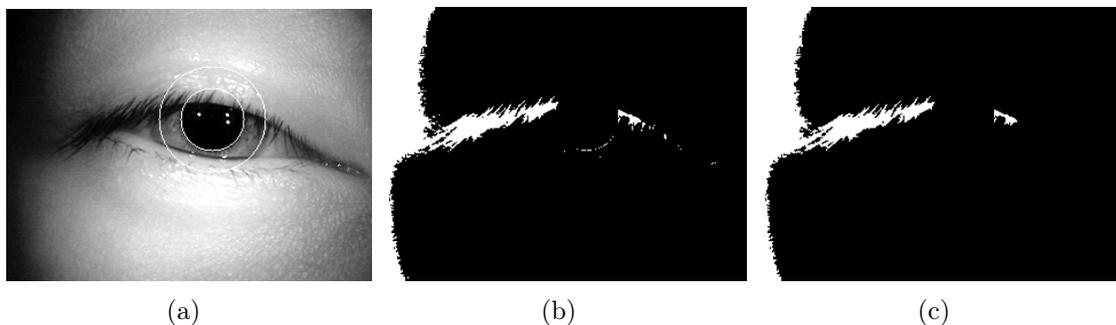


Figura 2.9: Etapas da localização dos cílios: (a) região usada para a elaboração do histograma da intensidade dos pixels da imagem; (b) resultado da binarização; (c) resultado final depois de apagar pontos sem interesse.

2.2.3 Íris

Com a localização da pupila e dos cílios, pode-se então buscar a borda externa da íris. Para isso usamos bordas obtidas mediante o uso do operador de Canny, empregando aquelas que estão localizadas no exterior do círculo que representa a borda da pupila e a uma distância não maior de 120 pixels do centro da pupila. A distância foi determinada experimentalmente observando as imagens do banco e calculando o tamanho da íris manualmente. Para reduzir os pontos das bordas que não são de interesse, os pontos cujos gradientes possuem direções similares à definida pelo vetor formado pelo ponto central da pupila e o ponto da borda são mantidos. Os pontos das bordas que foram detectadas no passo anterior como parte dos cílios são removidos. Finalmente, a transformada de Hough é aplicada para se obter o círculo que melhor represente a borda externa da íris, sabendo que o centro do círculo achado não pode estar afastado do centro da pupila. O processo da localização da borda externa da íris está representado na Fig. 2.10.

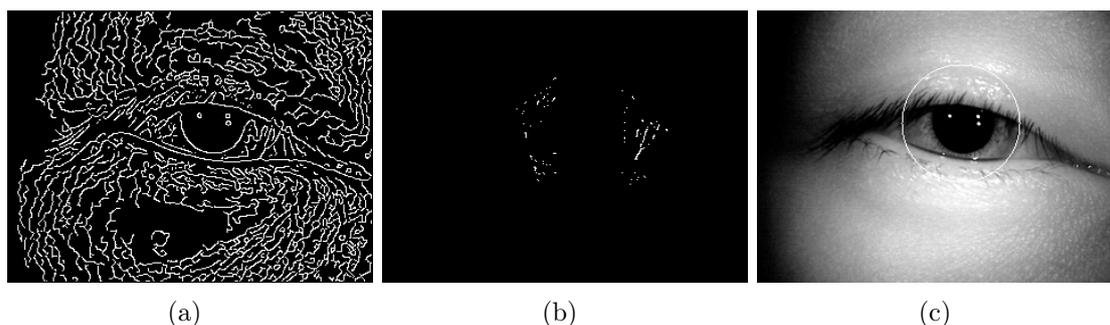


Figura 2.10: Etapas da localização da borda externa da íris: (a) bordas encontradas após aplicar o filtro de Canny; (b) redução do espaço e do número de pontos de interesse; (c) borda da íris localizada após a aplicação da transformada de Hough.

2.2.4 Pálpebras

Para localizar as pálpebras foram usadas somente as bordas detectadas pelo operador de Canny e situadas na faixa formada pelos círculos que representam as bordas (externa e interna) da íris (Fig. 2.11(a)). A imagem (Fig. 2.11(b)) foi dividida em duas partes, usando o centro da íris como ponto de corte. Para localizar as pálpebras superior e inferior, foram usados os pontos acima e abaixo do centro do círculo que representa a borda externa da íris, respectivamente. A transformada de Hough é usada separadamente (parte superior e inferior), para determinar as parábolas que coincidam em maior quantidade com os pontos das bordas detectadas (Fig. 2.11(c)).

Empregando o procedimento do parágrafo anterior, cada vez que é aplicada a transformada de Hough é obtida uma parábola. Mas é possível que a íris não esteja

fechada pelas pálpebras, como mostram algumas das imagens das Figs. 2.6 e 2.7. Para evitar falsas detecções, a quantidade dos pontos coincidentes das parábolas com os das bordas detectadas é comparado com um determinado limiar. Se a quantidade de pontos coincidentes for maior a parábola é aceita, caso contrario é rejeitada e se deduz que não houve pálpebra ocultando a região da íris. Neste trabalho o uso de 12 como valor do limiar mostrou um bom desempenho.

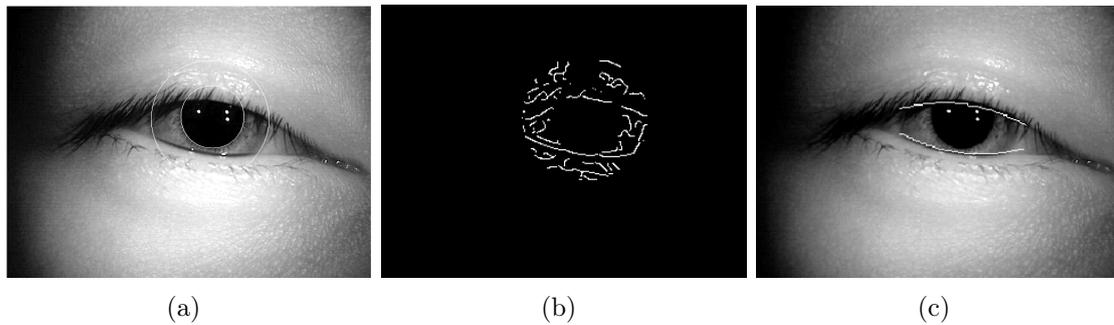


Figura 2.11: Etapas da localização das pálpebras: (a) delimitação da região de interesse; (b) bordas usadas para a localização das pálpebras; (c) pálpebras localizadas após a aplicação da transformada de Hough.

Após finalizar as etapas mencionadas anteriormente o processo de segmentação é completado. O resultado final com localização das bordas interna e externa da íris, as pálpebras e os cílios é mostrado na Fig. 2.12.

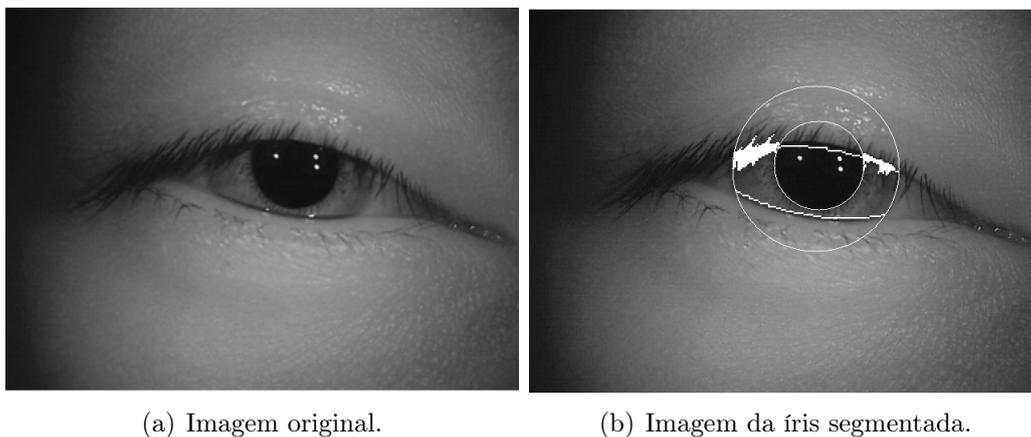


Figura 2.12: Segmentação da região da íris.

2.2.5 Resultados

Para mostrar a robustez e precisão do procedimento apresentado, o método foi testado usando os bancos CASIA, que incluem diversas condições reais como óculos,

pálpebras semi-fechadas e reflexos de luz. Foram 13.000 imagens do CASIA versão *Lamp* e 20.000 imagens do CASIA *Thousand* usados neste trabalho. Devido à quantidade de imagens nos bancos CASIA foram criados 10 subconjuntos, cada um contendo 1.000 imagens. Cada subconjunto foi criado da seguinte forma:

- Primeiro são escolhidos randomicamente 200 usuários do total de usuários do banco;
- Em seguida é escolhido aleatoriamente o olho esquerdo ou o direito para cada usuário;
- Finalmente 5 imagens do olho selecionado para cada um dos 200 usuários são escolhidas aleatoriamente.

Na segmentação descrita na Seção 2.2 foi indicado que se a pupila não for localizada numa determinada imagem, o método de segmentação é interrompido. Então nossa primeira avaliação foi determinar a quantidade de vezes que o algoritmo falhou na localização da pupila. Para isso foi criado um registro no qual foram guardadas as imagens nas quais a localização não teve sucesso. O número total de imagens registradas nos 10 subconjuntos dos dois bancos CASIA foi de só de 12 imagens, tendo como problema principal a oclusão da pupila por parte da íris e os cílios, como também reflexos perto da pupila. Alguns exemplos são mostrados na Fig. 2.13.



Figura 2.13: Imagens dos bancos CASIA nas quais não foi localizada a pupila.

O problema da localização da pupila pode ser abordado a partir de uma outra perspectiva. O algoritmo pode encontrar a pupila numa região errada da imagem, como por exemplo alguma outra zona escura. Como de fato esta avaliação tem que ser visual, foram selecionadas aleatoriamente 500 imagens de cada banco CASIA. Nas 1.000 imagens selecionadas não foi encontrada nenhuma imagem com uma localização errada da pupila.

Com respeito aos erros de segmentação, na íris foram achadas 17 imagens (1,7%) com erros na segmentação, nas pálpebras foram achados 24 erros (2,4%) e nos cílios foram achadas 32 erros (3,2%). Os principais problemas da segmentação da íris foi

devido ao operador de Canny não detectar corretamente a borda externa da íris. No caso dos cílios o problema foi causado em imagens muito escuras onde o algoritmo não consegue discriminar entre a íris e os cílios. A segmentação das pálpebras teve como maior problema a falsa localização. Também ocorreram casos em que o algoritmo não detectou a pálpebra. Nas Figs. 2.14 e 2.15 são ilustrados exemplos onde acontece uma boa segmentação e uma segmentação errada, respectivamente.

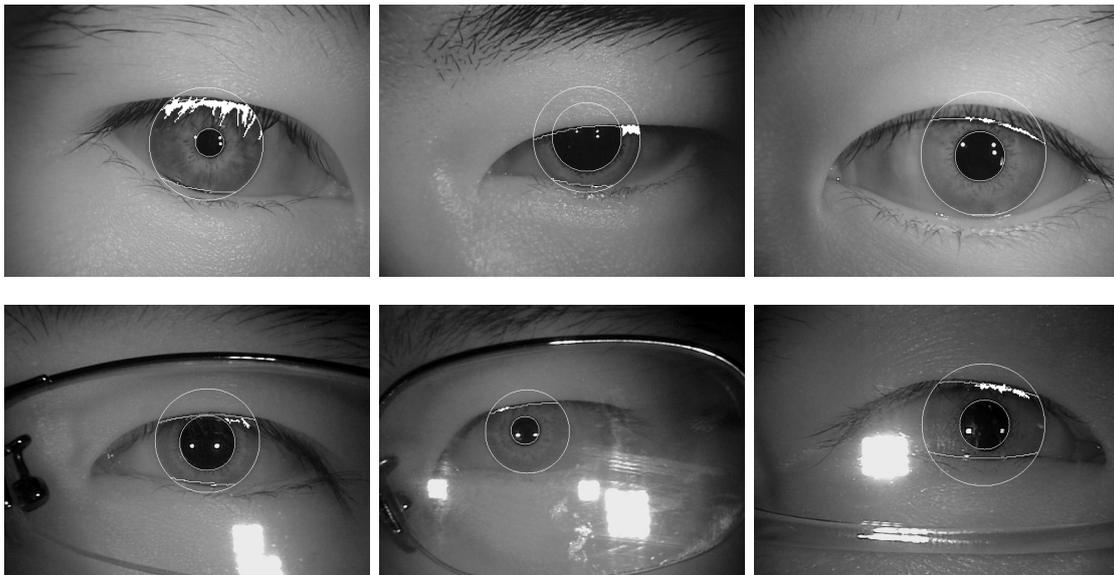


Figura 2.14: Imagens dos bancos CASIA segmentadas com sucesso.

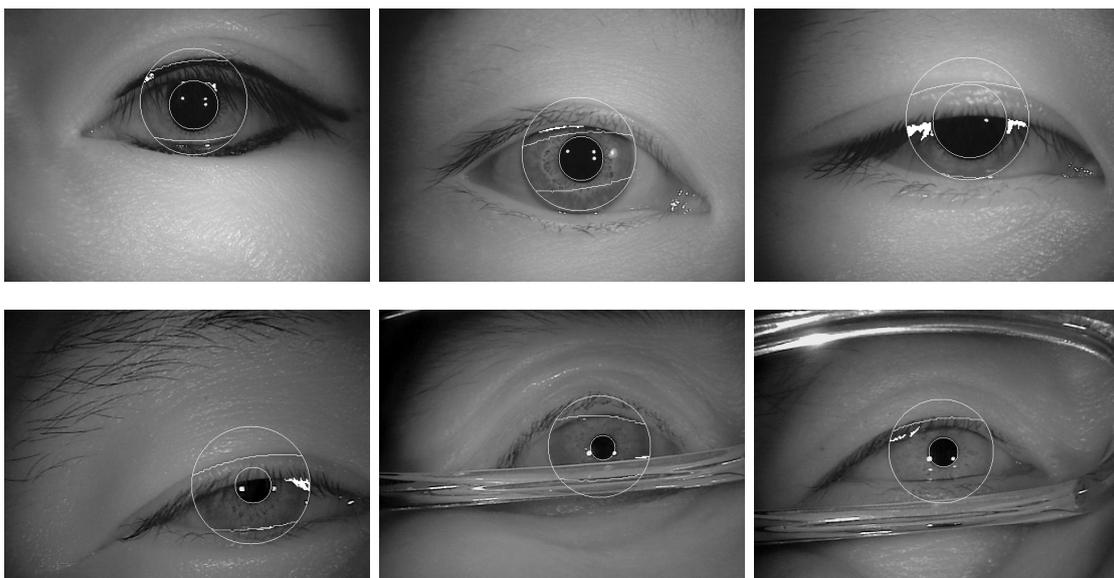


Figura 2.15: Imagens dos bancos CASIA com erros na segmentação.

Capítulo 3

Normalização

O procedimento de normalização tem como objetivo compensar, em primeiro lugar, as variações de distância entre o indivíduo e a câmera no momento da captura e, em segundo lugar, as contrações da pupila devido à iluminação, como pode ser observado na Fig. 3.1. A pupila atua como um dispositivo de abertura e fechamento do sistema óptico do olho. Durante as horas de vigília, o tamanho da pupila varia constantemente de acordo com a iluminação. O diâmetro da pupila pode variar entre um mínimo de 1,5 mm a um máximo que pode chegar a 7,5 mm. A íris possui um diâmetro exterior de cerca de 12 mm. Portanto, o diâmetro da pupila, no intervalo de 1,5-7,5 mm pode ocupar entre cerca de 12% a 60% do total do diâmetro da íris. Em consequência, o tecido da íris pode variar até 5 vezes em extensão circunferencial (para o tecido próximo à pupila), e cerca de 2 vezes em extensão radial. Pode ser visto, por conseguinte, que a estrutura da íris sofre deformação frequente e substancial, e portanto o procedimento de normalização da íris é de vital importância.

O método de normalização Daugman [3, 22] é usado como referência em diversos trabalhos, pois além de ser o pioneiro, sua técnica foi testada em bases de dados com milhões de pessoas. Neste capítulo será apresentado um novo método para a normalização da íris que usa a mesma idéia do método de Daugman, de transformar o anel da íris num retângulo de dimensões fixas, mas usando círculos não concêntricos em torno da pupila. Será explicado inicialmente o método proposto por Daugman, e depois nossa proposta de normalização. No Capítulo 5 serão mostrados os resultados dos testes de comparação dos métodos.

3.1 Método de normalização de Daugman

A normalização proposta por Daugman transforma o anel que corresponde à íris na imagem de entrada num retângulo de dimensões fixas. A imagem original $I(x, y)$ em coordenadas cartesianas é representada agora em um sistema de coordenadas



Figura 3.1: Diferentes posições do olho e dilatações da pupila.

polares na forma $I(r, \theta)$, cuja origem está no centro da íris. Esta transformação geométrica é conhecida por *rubber sheet model*, e é descrita pelas equações

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

$$x(r, \theta) = (1 - r)x_p(\theta) + rx_s(\theta) \quad (3.2)$$

$$y(r, \theta) = (1 - r)y_p(\theta) + ry_s(\theta) \quad (3.3)$$

onde $x_p(\theta)$, $y_p(\theta)$, $x_s(\theta)$ e $y_s(\theta)$ são, respectivamente, as coordenadas cartesianas do contorno da pupila e da esclera correspondentes ao ângulo θ . Nestas equações r pertence ao intervalo $[0, 1]$ e θ pertence ao intervalo $[0, 2\pi]$. Detalhes desta transformação estão ilustrados na Fig. 3.2.

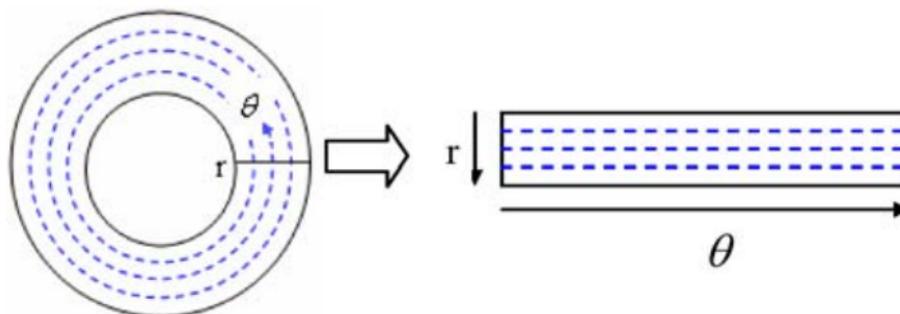


Figura 3.2: Método de normalização de Daugman.

3.2 Proposta de normalização da íris

Nossa proposta está baseada no fato de que se os círculos que representam a pupila e a íris fossem concêntricos, o processo de transformação do anel que corresponde à íris num retângulo de dimensões fixas se tornaria bem mais rápido e simples de executar e implementar, com respeito ao método proposto por Daugman. Então,

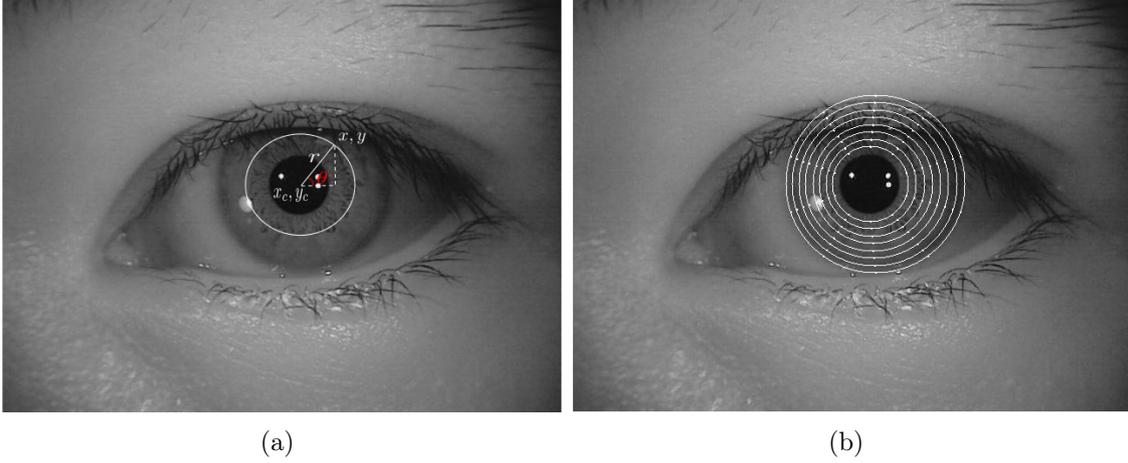


Figura 3.3: Detalhes do método proposto usando círculos concêntricos.

considerando que a pupila e a íris sejam concêntricas, o método de transformação pode ser descrito pelas equações seguintes:

$$A(n, m) = I(x(n, \theta), y(n, \theta)) \quad (3.4)$$

$$\theta = 2\pi \frac{m}{M} \quad (3.5)$$

$$x(n, \theta) = r \cos \theta + x_c \quad (3.6)$$

$$y(n, \theta) = r \sin \theta + y_c \quad (3.7)$$

$$r = r_p + \frac{n-1}{N}(r_i - r_p) \quad (3.8)$$

onde I representa a imagem da íris, A representa o anel da íris transformada numa matriz de dimensões fixas, $m \in [1, M]$ e $n \in [1, N + 1]$. As variáveis x_c e y_c são as coordenadas do centro da íris e da pupila respectivamente, r_p e r_i são os raios dos círculos que representam a pupila e a íris, respectivamente. Portanto, a quantidade de círculos a serem criados dependerá da quantidade de linhas (N) da matriz A , como ilustrado nas imagens da Fig. 3.3.

Como se pode observar na Fig.3.4(a), o problema desta aproximação se deve ao fato de que a pupila não é em geral concêntrica com a íris. Fizemos uma pesquisa com mais de 2000 imagens do banco de CASIA, escolhidas das imagens segmentadas no Capítulo 2. Cada imagem foi verificada para ter certeza de uma correta localização dos círculos que representam as bordas da íris. A pesquisa mostrou que nas quase 50% das imagens a pupila tem um deslocamento, como se pode observar no histograma mostrado na Fig. 3.4(b).

Para contornar o problema do deslocamento da pupila, propomos usar centros diferentes para cada círculo criado. Os centros são posicionados de forma equidistante na linha reta que une o centro da pupila e o centro da íris. A distância entre

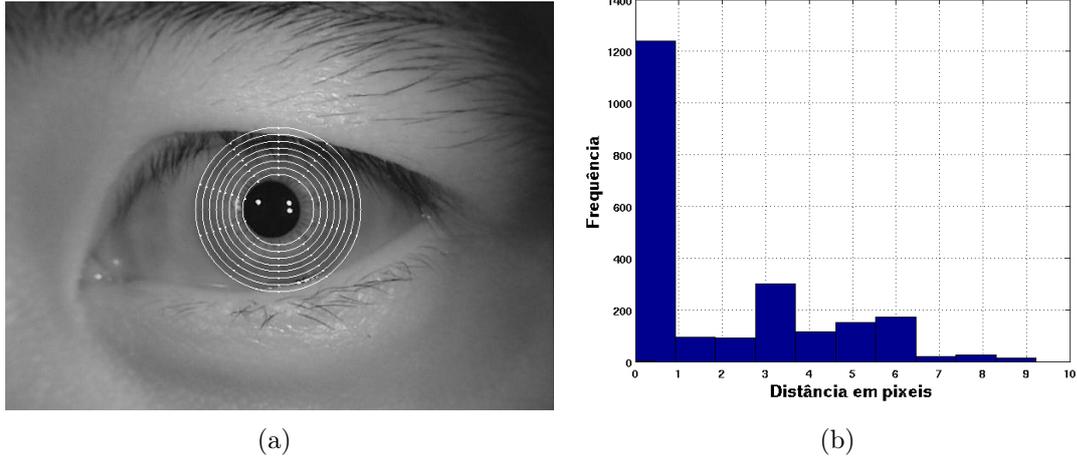


Figura 3.4: Problema das pupilas deslocadas: (a) exemplo do uso dos círculos concêntricos numa pupila deslocada do centro da íris; (b) histograma do deslocamento da pupila do centro da íris.

eles é determinada pela distância entre o centro da pupila e centro da íris dividido pela quantidade de círculos a serem criados. O primeiro centro é posicionado no centro da pupila, e o último no centro da íris. Os centros intermediários são ser posicionados gradualmente entre a pupila e a íris. O raio de cada círculo é aumentado proporcionalmente, sendo que o primeiro raio é igual ao raio da pupila e o último ao raio da íris. O aumento é definido pela diferença entre os raios da pupila e da íris dividido pela quantidade de círculos a serem criados.

Reformulando as equações do método dos círculos concêntricos para o método dos centros variáveis, obtêm-se:

$$A(n, m) = I(x(n, \theta), y(n, \theta)) \quad (3.9)$$

$$\theta = 2\pi \frac{m}{M} \quad (3.10)$$

$$x(n, \theta) = r \cos \theta + x_c^n \quad (3.11)$$

$$x_c^n = x_c^1 + \frac{n-1}{N} D \quad (3.12)$$

$$y(n, \theta) = r \sin \theta + y_c \quad (3.13)$$

$$y_c^n = y_c^1 + \frac{n-1}{N} D \quad (3.14)$$

$$r = r_p + \frac{n-1}{N} (r_i - r_p) \quad (3.15)$$

onde I representa a imagem da íris, A representa o anel da íris transformada numa matriz de dimensões fixas, $m \in [1, M]$ e $n \in [1, N + 1]$. As variáveis x_c^1 e y_c^1 são as coordenadas x e y do centro da pupila, e D é a distância euclidiana entre o centro

da pupila e o centro da íris. A Fig. 3.5 mostra os círculos não concêntricos usados para normalizar a íris numa matriz de três linhas e M colunas.

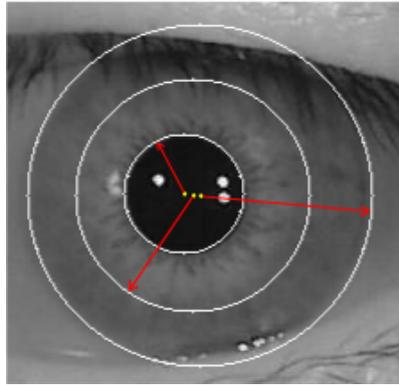
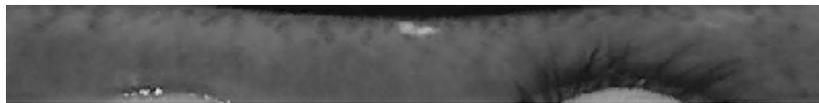


Figura 3.5: Círculos não concêntricos usados para normalizar a íris.

Os resultados da normalização da imagem da Fig. 3.4(a) fazendo uso dos três métodos são apresentados na Fig. 3.6.



(a) Íris normalizada fazendo uso do método de Daugman.



(b) Íris normalizada fazendo uso de círculos concêntricos.



(c) Íris normalizada fazendo uso de círculos variados.

Figura 3.6: Imagens da íris normalizada.

3.3 Comparação dos métodos

O método de normalização proposto foi submetido a duas avaliações. Primeiro foi avaliado o desempenho no processo de reconhecimento, e depois foi avaliada a performance em termos de tempo de processamento, ambos com respeito ao método de normalização de Daugman.

3.3.1 Avaliação no reconhecimento

Para avaliar o desempenho no reconhecimento, foram empregados os subconjuntos das versões *Lamp* e *Thousand* do banco CASIA criados no Capítulo 2. Porém, 12 imagens não tiveram a segmentação concluída devido a que a pupila não foi localizada corretamente. Portanto, a quantidade de imagens em alguns subconjuntos para a avaliação do reconhecimento foi diminuída de 1.000 para 999, mas essa pequena diminuição não afetou a avaliação.

O método desenvolvido durante a pesquisa do mestrado [39], e que será explicado no capítulo seguinte, foi executado para cada subconjunto usando ambas as normalizações. As medidas para avaliar o desempenho no reconhecimento foram a decidibilidade (DEC) proposta por Daugman em [49] e a *Equal Error Rate* (EER).

Num algoritmo de reconhecimento as pessoas são identificadas e avaliadas, sendo classificadas de duas formas: (*intra-class*) quando nos referimos à mesma pessoa e (*inter-class*) quando são pessoas diferentes, resultando uma distribuição para cada uma das classificações. A decidibilidade é a medida que relaciona a distância entre as duas distribuições, analisando o quanto estão separadas, e pode ser medida por:

$$\frac{|\mu_I - \mu_E|}{\sqrt{0.5 \sigma_I^2 + 0.5 \sigma_E^2}} \quad (3.16)$$

onde μ_I e μ_E denotam as médias da *intra-class* e *inter-class*, respectivamente, e σ_I e σ_E os correspondentes desvios padrão.

O EER é o ponto onde as taxas de falsos positivos e falsos negativos são iguais em valor. Um falso positivo acontece quando o sistema biométrico aceita um usuário quando ele alega que é outra pessoa. O falso negativo acontece quando o sistema não aceita um usuário legítimo. Quanto menor for o EER melhor será algoritmo.

Nas Figs. 3.7 e 3.8, são apresentados os resultados da DEC e o EER nas versões *Lamp* e *Thousand*, respectivamente. As curvas mostram os valores obtidos em cada um dos 10 subconjuntos criados de cada versão do banco CASIA. É possível observar que a normalização proposta tem um desempenho um pouco inferior com respeito ao método proposto por Daugman, nas duas medidas usadas para avaliar a performance.

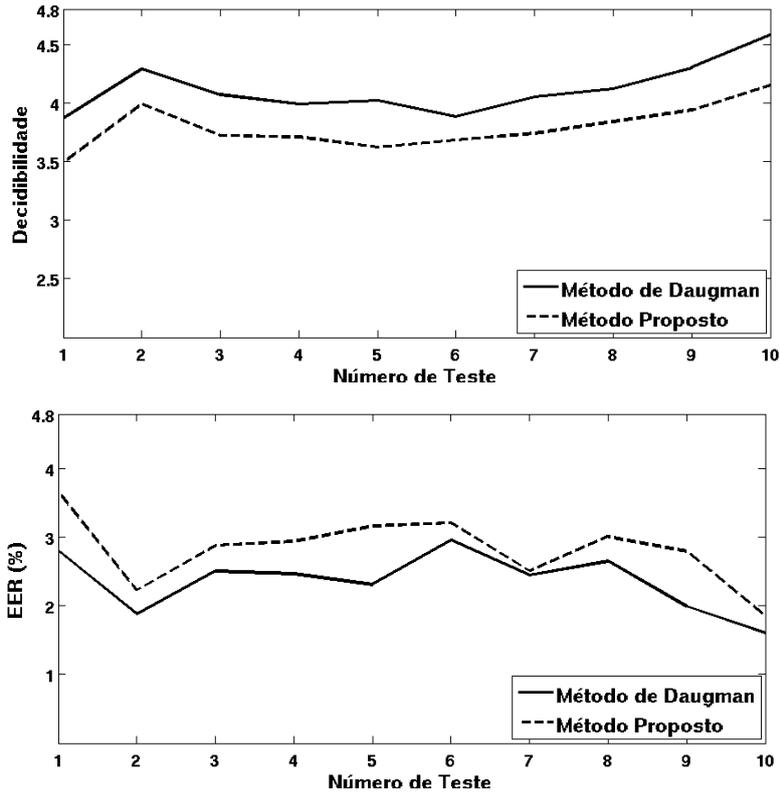


Figura 3.7: Valores da decidibilidade e do EER para cada teste na versão *Lamp*.

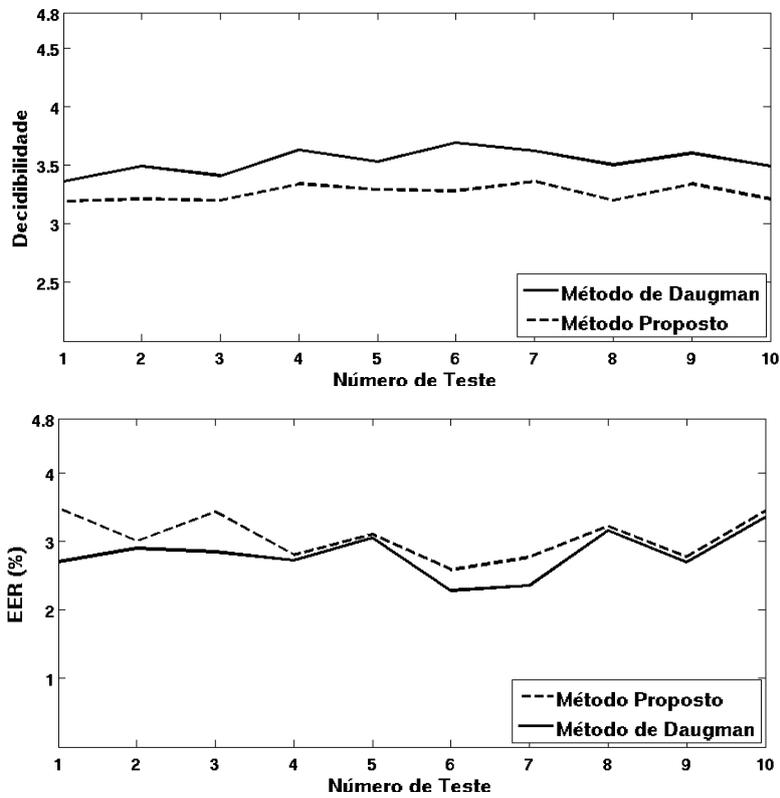


Figura 3.8: Valores da decidibilidade e do EER para cada teste na versão *Thousand*.

3.3.2 Avaliação no tempo de processamento

A normalização proposta por Daugman foi testado em mais de 200 bilhões de comparações [50], e é utilizada na maioria de métodos de reconhecimento biométricos da íris. Porém, cada método de reconhecimento que emprega a normalização de Daugman utiliza diferentes dimensões para normalizar a íris. Em [8] é utilizado o método de normalização de Daugman para transformar a íris num retângulo de 64×512 . Em [11] utiliza-se também o método de Daugman para normalizar a íris num retângulo de 80×512 . Nos testes de desempenho da seção anterior empregamos a íris normalizada em dimensões de 32×512 . Segundo Daugman [3], seu método de reconhecimento normaliza a íris somente num retângulo de 16×256 .

Devido às diferentes dimensões utilizadas para normalizar a íris nos métodos encontrados na literatura, a íris foi normalizada em retângulos de diferentes dimensões, e os tempos da normalização proposta comparados ao método de normalização proposto por Daugman.

Na Tabela 3.1 são mostradas algumas dimensões de normalização com seus respectivos tempos de processamento. É possível observar que o ganho no tempo de processamento pode chegar até quase 98% (vinte vezes mais rápido). O ganho depende das dimensões em que a íris é normalizada. A Fig 3.9 mostra a curva do ganho do tempo de processamento para diferentes dimensões de normalização da íris. Os tempos foram registrados usando um computador com processador Intel Quad-Core 2.66 GHz com 8 Gb de memória RAM, e os algoritmos programados em Matlab. Os tempos obtidos para o método de Daugman ficaram muito próximos do trabalho publicado em [51], que utiliza também o Matlab e um computador com características semelhantes.

Tabela 3.1: Tempo requerido para completar o processo de normalização da íris.

| Dimensões | Pixeis | Daugman (ms) | Proposto (ms) | Ganho (%) |
|-----------|--------|--------------|---------------|-----------|
| 16x256 | 4096 | 50 | 3.92 | 92.16 |
| 32x512 | 16384 | 186 | 5.42 | 97.10 |
| 48x448 | 21504 | 239 | 6.66 | 97.21 |
| 64x512 | 32768 | 365 | 7.71 | 97.90 |

A proposta de normalização revela uma diminuição no desempenho do reconhecimento, mas é significativamente superior em tempos de processamento. A vantagem no tempo de processamento pode beneficiar certos sistemas para melhorar o resultado final do reconhecimento, como por exemplo nos sistema multiamostras.

Também, a normalização proposta nesta pesquisa permite processar uma maior quantidade de amostras no mesmo intervalo de tempo. Para citar um exemplo, utilizamos o método reconhecimento que foi empregado para avaliar a proposta de

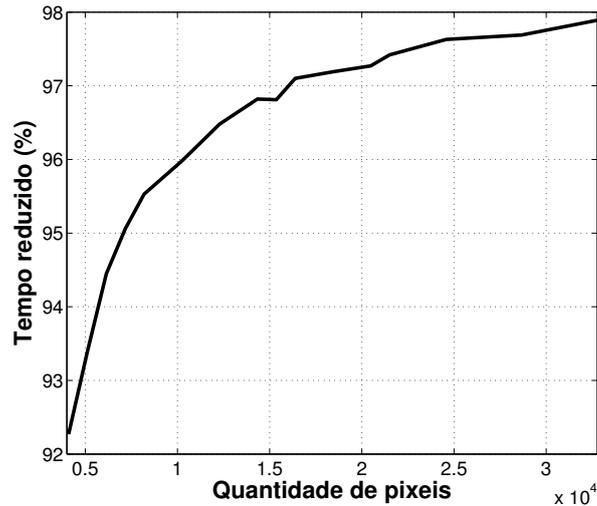


Figura 3.9: Redução do tempo do processo de normalização versus o número de pixels da íris normalizada.

normalização. O método de normalização de Daugman, permite só processar três imagens no intervalo de 1 segundo. Ao aplicar o método de normalização proposto o sistema poderia avaliar 8 amostras no mesmo intervalo. Dependendo das dimensões da íris normalizada, empregando o método de Daugman o número de amostras processadas seria ainda menor do que três.

Um outro cenário de interesse pode ser a etapa de testes dos métodos de reconhecimento, onde usualmente são empregadas milhares de imagens que criam milhões de combinações. Uma base de dados com 5.000 imagens cria mais de 12 milhões de comparações. A diferença de tempo dos métodos de normalização empregando um retângulo de 32×512 é de 0.180 ms, isso tornaria possível poupar 624 horas de trabalho (26 dias). Já para a implementação final do sistema poderia ser implementado o método de normalização de Daugman, garantindo que o desempenho do reconhecimento sofra menor degradação.

Capítulo 4

Identificação de indivíduos usando imagens capturadas sem cooperação

Diversos sistemas de segurança biométricos precisam majoritariamente de colaboração por parte dos usuários. Alguns sistemas, no caso da íris, obrigam ao usuário uma maior colaboração para que os detalhes da estrutura da íris sejam capturados com clareza. Sistemas como a impressão digital, mão e rosto, entre outros, precisam bem menos a colaboração dos usuários, mas esses sistemas não têm a performance em termos de reconhecimento dos sistemas que usam a íris. Também é importante realçar que não é necessário um conhecimento muito avançado para conseguir uma suplantação com sucesso em sistemas biométricos que usam a impressão digital ou rosto.

No entanto existem situações onde é necessário identificar as pessoas sem precisar que ofereçam certo grau de cooperação. Para citar um exemplo, num estádio de futebol devido a quantidade de pessoas que podem assistir a um jogo, poderia tornar inviável um procedimento de cooperação dos usuários. Uma possibilidade seria utilizar uma câmera colocada num corredor para capturar imagens da íris das pessoas. Mas este tipo de sistema pode apresentar certos problemas; como diminuição da qualidade dos detalhes da íris, devido ao usuário não estar perto da câmera. Outro problema seria o ângulo de captura da imagem, porque os usuários nem sempre fixariam a mirada na câmera.

Sistemas que usam a íris para o reconhecimento e que tenham a captura da informação comprometida pelos motivos descritos no parágrafo anterior, poderiam ser auxiliados por métodos biométricos perioculares. Além de não precisar de um equipamento adicional, o sistema poderia requerer somente uma atualização do *software* para aproveitar as características perioculares. As imagens do banco UBIRIS.v2 [35] utilizadas no *Noisy Iris Challenge Evaluation - Part 2* (NICE.II) [34], apresenta características que podem ser interpretadas como capturas de um sistema de identificação sem cooperação dos usuários. No Capítulo 2 foi mostrado que as ima-

gens apresentavam capturas em diferentes poses, e a diferentes distâncias da câmera. Além destas características, as imagens foram capturadas no espectro visível, que faz com que os detalhes da íris não sejam tão notórios como quando a íris é capturada com luz infravermelha. Estas características do banco UBIRIS.v2, fazem com que o objetivo de criar um sistema biométrico de reconhecimento seja um desafio interessante.

A seguir é detalhada a proposta de um sistema biométrico multimodal desenvolvida nesta pesquisa, e que participou da competição NICE.II. A proposta emprega métodos que extraem as características da íris e da região periocular, para depois serem fusionados com o objetivo de conseguir uma identificação correta dos usuários. Na última seção deste capítulo serão apresentados os resultados obtidos nos testes de desempenho.

4.1 Sistema biometrico multimodal para imagens sem cooperação dos usuários

A proposta de um sistema biométrico multimodal a ser descrita está publicada em [43]. Nesta fusão são usadas diferentes técnicas de reconhecimento, cada uma extraindo diferentes propriedades dos olhos, que depois serão unidas para incrementar a robustez da degradação que é típica dos sistemas de aquisição não cooperativos. As técnicas usadas neste propósito podem ser divididas em duas categorias principais. No primeiro enfoque usamos wavelet para extrair as características da estrutura da íris junto com a representação do zero-crossing, e uma análise da distribuição dos bits na comparação do *iriscode*. Adicionalmente, expandimos a extração das características na região periocular. Segundo [52] e [53], a região em torno do olho possui características que favorecem uma melhor performance do reconhecimento com respeito à íris em imagens capturadas em condições não ideais. A nova fusão ficou em evidência ao conseguir o terceiro lugar no *Noisy Iris Challenge Evaluation - Part 2*. O primeiro lugar [45] foi conferido ao grupo do laboratório de CASIA, seguido pelo o *Techshino Biometrics Research Center*, mostrando a qualidade dos participantes nesta competição.

O sistema de reconhecimento multimodal detalhado neste capítulo contém cinco etapas: (i) detecção das bordas interna e externa da íris que foi ilustrada no Capítulo 2, (ii) normalização da íris, (iii) representação ou extração de características para cada método individual, (iv) comparação ou *matching* também para método individual, e finalmente (v) a fusão dos métodos empregados. Na Fig. 4.1 é mostrado graficamente o procedimento das etapas da proposta. Em seguida serão detalhados individualmente os procedimentos de representação e comparação para cada método

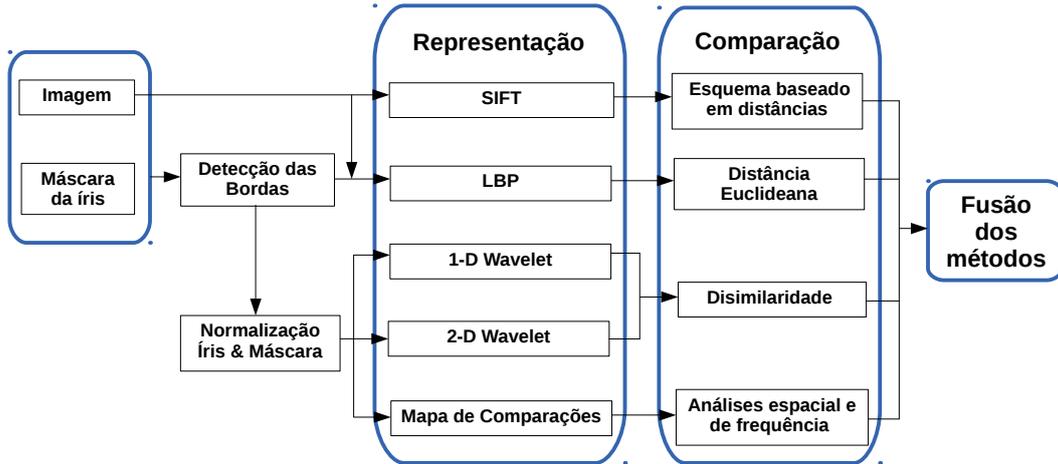


Figura 4.1: Metodologia proposta.

usado, para depois apresentar a fusão deles.

4.1.1 Método de mapas de comparações

O método foi desenvolvido segundo as orientações dos autores publicadas em [38], e analisa o resultado obtido pelo método de identificação de Daugman [3] para melhorar o desempenho no reconhecimento. O método analisa no domínio espacial e no domínio da frequência as áreas de concordância entre duas íris normalizadas. O método de Daugman extrai as características da íris normalizada usando o filtro Gabor 2D. A íris e sua máscara correspondente são normalizadas numa imagem de dimensões 450×64 usando procedimento de normalização da íris proposto por Daugman e explicado no Capítulo 2. A íris normalizada é depois quantizada para produzir o que Daugman denomina de *IrisCode*, utilizando seguinte equação:

$$h_{\{Re,Im\}} = \mathbf{sgn}_{\{Re,Im\}} \int_{\rho} \int_{\phi} I(\rho, \phi) e^{-iw(\theta_0 - \phi)} e^{-(r_0 - \rho)^2 / \alpha^2} e^{-(\theta_0 - \phi)^2 / \beta^2} \rho d\rho d\phi \quad (4.1)$$

onde $h_{\{Re,Im\}}$ pode ser considerado como um bit de um valor complexo em que as partes real e imaginária são 1 ou zero, dependendo do sinal da integral 2D definida pela Eq. (4.1). A imagem da íris normalizada é representada por $I(\rho, \phi)$, α e β são os parâmetros da wavelet, w é a frequência da wavelet, e (r_0, θ_0) são as coordenadas polares da região da imagem. Na Fig. 4.2 é mostrado um exemplo da codificação da íris segundo Daugman.

Para determinar a similaridade entre duas representações de íris (*IrisCode*) Daugman usa a distância de Hamming (Eq. 4.3), onde *codeA* e *codeB* são duas *IrisCode* obtidas pela Eq. 4.1, e suas respectivas máscaras *maskA* e *maskB*, que

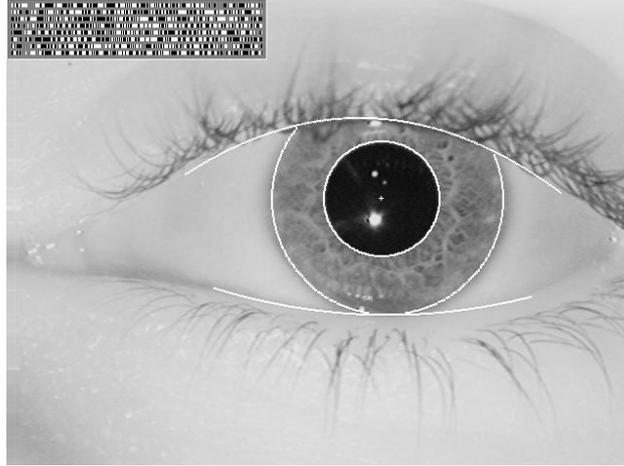


Figura 4.2: Codificação da íris (*IrisCode*) [3].

representam a oclusão causada pelas pálpebras, cílios ou reflexos.

$$c = (codeA \otimes codeB) \cap maskA \cap maskB \quad (4.2)$$

$$HD = \frac{\|c\|}{\|maskA \cap maskB\|} \quad (4.3)$$

Na Fig. 4.3 são mostradas duas comparações de *IrisCode* que contêm a mesma distância de Hamming, onde os pixels pretos representam os bits de concordância entre duas íris. Observando as imagens, os autores concluíram (intuitivamente) que o mapa de concordância da Fig. 4.3(b) possui uma alta probabilidade de corresponder a uma comparação entre duas *IrisCode* que representam a mesma íris.



(a) Comparação de duas *IrisCode* com uma regular distribuição de concordância.



(b) Comparação de duas *IrisCode* com uma área de alta concordância (região delimitada).

Figura 4.3: Mapas de comparação.

Portanto, ao invés de usar apenas a distância Hamming (que é simplesmente a proporção de bits dos *IrisCode* concordantes) como uma medida de comparação, a comparação resultante que denominada pelos autores como mapas de comparações foi submetida a análises no domínio espacial e no domínio da frequência em busca de áreas de concordância (Fig. 4.3(b)).

Domínio Espacial

Para determinar o nível de concordância em regiões de diferentes dimensões, é realizado um conjunto de convoluções usando wavelets de Haar de diferentes comprimentos. Seja c um mapa de comparações de dimensões $M \times N$, e h uma wavelet Haar mãe de dimensão $s \times s$. A similaridade r nas regiões locais de c é dada por:

$$r_s = h_s * c \quad , s = \{2k\}, k = 2, 3, \dots, 16 \quad (4.4)$$

onde $*$ é a convolução bi-dimensional, e r_s tem as mesmas dimensões de c .

Seja $\omega_s = \max\{r_s(i, j)\}$, $i = 1, 2, \dots, N$; $j = 1, 2, \dots, M$, e H um histograma 25-bin de $r_{\frac{\psi}{2}}$ onde ψ é a maior dimensão da wavelet Haar mãe, tal que $H = \{v_1, v_2, \dots, v_{25}\}$. Os 15 valores do ω_s e os 25 valores do v_i serão usados posteriormente no processo de classificação.

Domínio da Frequência

Junto com a análise descrita anteriormente também são analisadas as frequências espalhadas dos bits concordantes. A justificativa é que a comparação entre *IrisCode* da mesma íris deve fornecer uma estreita distribuição de ruído branco de bits concordantes. Ao contrário, uma comparação entre dois *IrisCode* de diferentes íris deve apresentar uma maior quantidade de componentes de baixa frequência, de acordo com a mesma idéia explicada anteriormente.

Nesta fase, são realizadas duas modificações para a abordagem de Daugman: a remoção da etapa de conversão para o sinal binário, e a substituição da operação da Eq. (4.2) pela diferença entre os coeficientes. Ao aplicar a transformada de Fourier nos mapas de comparações e no diferencial binário, verificou-se que os últimos produzem resultados mais discriminantes, o que é facilmente justificado pela maior quantidade de informações.

Seja c o mapa de comparações de dimensões $M \times N$. A Transformada de Fourier bidimensional F é dada por:

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^M \sum_{y=0}^N c(x, y) e^{-j2\pi(ux/M+vy/N)} \quad (4.5)$$

O resultado foi então decomposto em 16 sub-regiões, regularmente distribuídas em pequenas janelas de dimensões 8×4 , e as características estatísticas, ou seja, valores de máximos, mínimos, médias, entropia e desvios-padrão, foram extraídos a partir de cada região, totalizando 80 valores. Para a parte central, onde se pode encontrar informação relevante, é considerada uma janela $P \times N$ centrada na matriz $P \times M$, tal que $P = 2M/8$. Dez características F_i são então extraídas, e cada uma

é representada em um histograma 10-bin, de acordo com as seguintes relações:

$$T_i = \min(A) + i \frac{\Delta A}{10} \quad (4.6a)$$

$$F_i = \sum_{m=1}^P \sum_{n=1}^N \text{sgn}(A_{(m,n)} - T_i) \quad (4.6b)$$

onde $\Delta A = \max(A) - \min(A)$ e $i = 1, 2, \dots, 10$.

Classificação

Juntando a distância de Hamming 4.3 e os valores obtidos nas análises do domínio espacial e da frequência teremos 221 valores. Cada um deles é considerado como características extraídas da íris. Os autores combinaram as 125 melhores características (de acordo com a sua dedicabilidade [49] individual) e realizaram uma redução da dimensionalidade para 15 dimensões através da análise local do discriminante de Fisher [54]. A Regressão Logística [55] foi utilizada para indicar a função que vai produzir o resultado final para este método.

4.1.2 Método usando a Wavelet 1-D

O método de representação utilizado nesta seção é uma extensão do método proposto por Boles [5, 6]. Esta extensão foi desenvolvida no mestrado [39], e estudos realizados [40–42] mostraram que a extensão proposta melhora significativamente o desempenho do reconhecimento em relação ao método original.

O valor da intensidade do pixel da imagem da íris normalizada é usado como ponto de partida para representação. Como foi feito no método do mapas de comparações da Seção 4.1.1, a normalização proposta por Daugman foi também usada aqui. O tamanho empregado da íris normalizada e da sua respectiva máscara foi 16×200 , quase 90% menos pixels do que o requerido pela extensão de Daugman. Cada linha da imagem normalizada forma um vetor que é depois tratado como um único período de uma amostra unidimensional de um sinal periódico. Nesta representação duas imagens normalizadas são analisadas, sendo uma delas a imagem da íris normalizada (Fig. 4.4(a)). A máscara da íris normalizada (Fig. 4.4(b)) é utilizada criar uma outra imagem com os pixels zerados representando a oclusão da imagem, como é mostrado na Fig. 4.4.

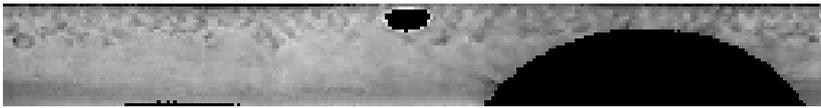
A transformada wavelet 1-D do tipo Gaussiana [56] é aplicada a cada vetor e decomposta em diferentes níveis, que em nosso caso foram os níveis dois e quatro. Então são localizados os zero-crossings e é calculada a energia entre dois zero-crossings consecutivos, para cada vetor e nível diferente da wavelet.



(a) Imagem da íris normalizada.



(b) Imagem da máscara da íris normalizada.



(c) Imagem normalizada com a oclusão zerada.

Figura 4.4: Imagens normalizadas.

Na Fig. 4.5 são mostradas as wavelets de um mesmo nível de resolução (linhas tracejadas) e suas representações de zero-crossing (linhas sólidas cinza escuro e cinza claro), de uma linha da imagem normalizada (linha sólida cinza escuro) e da imagem normalizada com a oclusão zerada (linha sólida cinza claro). A linha sólida preta corresponde à representação final da imagem normalizada.

Pode-se perceber que as wavelets (e suas respectivas representações de zero-crossing) diferem nas regiões com a oclusão identificada (zerada). Portanto, a representação final é produzida pela representação do zero-crossing (linha sólida cinza escuro) da imagem normalizada (Fig. 4.4(a)), zerando onde houver diferença com respeito à representação (linha sólida cinza claro) do zero-crossing da imagem normalizada com a oclusão zerada (Fig. 4.4(c)).

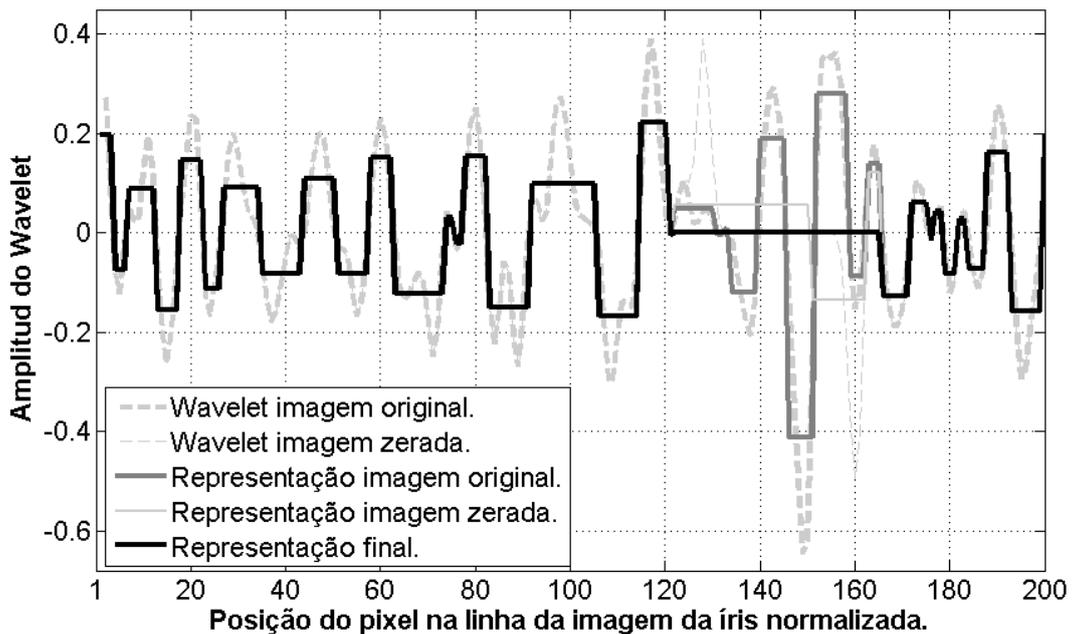


Figura 4.5: Representações da wavelet e do zero-crossing.

Comparaçãõ

Boles et al. [6] propõem 4 funções para medir a dissimilaridade. Neste trabalho usaremos a medida de dissimilaridade definida por [6]:

$$d_{lm}(f, g) = 1 - \frac{\sum_{e=0}^{E-1} Z_l f(e) \cdot Z_l g(e + m)}{\|Z_l f\| \|Z_l g\|}, \quad (4.7)$$

onde $d_{lm}(f, g)$ denota a dissimilaridade entre duas íris f e g da l -ésima linha da matriz de representação para um deslocamento m , e os vetores $Z_l f$ e $Z_l g$ representam a l -ésima linha da matriz de representação das íris f e g , respectivamente. O parâmetro E representa o número de elementos de $Z_l f$ e $Z_l g$, $m, e \in [0, E - 1]$. O símbolo $\|\cdot\|$ denota a norma de um vetor. Nota-se que $d_{lm}(f, g)$ é igual a 1 menos o coeficiente de correlação entre $Z_l f(e)$ e $Z_l g(e)$, e, conseqüentemente, a dissimilaridade $d_{lm}(f, g)$ pode ter valores entre 0 e 2, onde 0 representa uma comparação perfeita.

Cada linha da representação das matrizes é computada pela Eq. (4.7) e depois a média ponderada é calculada para representar a dissimilaridade (D_m) entre duas íris f e g para cada valor de m . Os pesos usados na média ponderada são dados pelos números de valores não zerados em $Z_j f(n)$ e $Z_j g(n)$, como é mostrado na equação

$$D_m = \frac{\sum_{l=1}^L d_{lm}(f, g) \times K_l}{\sum_{l=1}^L K_l} \quad (4.8)$$

onde $d_{lm}(f, g)$ é dada pela Eq. (4.7) e K_l é o número de valores não zerados na l -ésima linha da representação do zero-crossing das íris f e g .

É importante realçar que m na Eq. (4.7) representa o deslocamento do segundo sinal. O valor do deslocamento m vai de 0 até $E - 1$. Finalmente, a dissimilaridade D entre duas íris f e g é dada por:

$$D = \min(D_m) \quad (4.9)$$

4.1.3 Método usando Wavelet 2-D

No método anterior usamos uma wavelet 1-D. No procedimento a seguir é usada a wavelet 2-D do tipo Daubechies Diadica [56]. A wavelet é aplicada nas duas imagens usadas anteriormente, ou seja, a imagem original ((Fig. 4.4(a)) e a imagem com a oclusão zerada (4.4(c)). Depois são calculadas suas respectivas representações, a partir da energia entre dois *zero-crossing* consecutivos, para cada linha da matriz resultante. Na representação final é usada a representação da imagem original mantendo os valores iguais e zerando quando existir diferença entre as duas representações. Finalmente, na etapa de comparação é aplicada a mesma função empregada na seção anterior (Sec. 4.1.2).

4.1.4 Método usando o *Local Binary Pattern*

O sistema de visão humano, além de poder distinguir objetos baseados na cor, é capaz de distinguir a textura. A principal característica da textura é a repetição de um padrão ou de vários padrões contidos numa determinada região. O padrão pode se repetir exatamente, ou se comportar como um conjunto de pequenas variações. O *Local Binary Pattern* (LBP) [37] (LBP) é um operador de análise de texturas em escala de cinza. Seu valor é calculado através de um valor binário atribuído a cada pixel da imagem, formando uma vizinhança linear de raio maior ou igual a 1 ao redor do pixel principal posicionado em uma região central. A partir dessa vizinhança é realizada uma comparação dos valores dos pixels vizinhos com o valor do pixel central, atribuindo 0 aos valores dos vizinhos inferiores e 1 aos superiores, gerando uma matriz de 0's e 1's.

O LBP foi usado em outros trabalhos para identificar pessoas empregando as características perioculares [30, 31, 57]. A diferença neste trabalho está nas imagens utilizadas. Elas contêm grandes mudanças na escala e na pose, fazendo que o processo de reconhecimento tenha uma menor performance. Devido às mudanças de escala e pose nas imagens, determinamos utilizar uma região ao redor do olho que mostrava ser menos afetada pelas mudanças.

A seguir é detalhado o procedimento da extração das características (Representação) das imagens dos usuários. Depois é explicado o procedimento de comparação entre duas representações.

Representação

Conhecidas a localização e as dimensões da íris, as imagens são alinhadas e normalizadas em escala e translação como um conjunto de regiões de interesse (Fig. 4.6) que foram definidas numa malha de 35 regiões (5×7). Como mostrado, as dimensões da íris são proporcionais aos lados da região de interesse, e o ponto central corresponde ao ponto central da íris.

Os descritores do LBP foram extraídos, como ilustrado na Fig. 4.6. Usando as intensidades dos pixels, a janela é iterada acima da região de interesse. A diferença entre o ponto central e os 8 pontos vizinhos é computada e o sinal é usado para produzir um resultado binário. Os resultados são convertidos para forma decimal e os valores de cada região de interesse são quantizados em histogramas de 8 bins. Finalmente, os sinais são concatenados para produzir um vetor de 280 elementos (35 regiões x 8 bins por região).

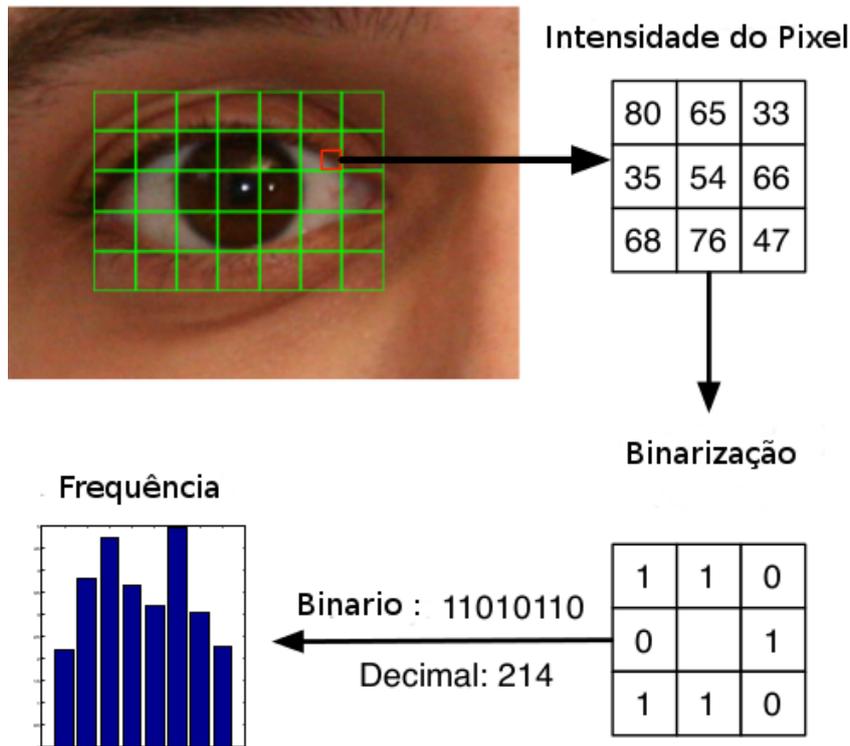


Figura 4.6: Passos para extração de características da íris.

Comparação

Para medir a similaridade entre os dois vetores resultantes no passo anterior, foi usada a distância euclidiana:

$$d(u, v) = \sqrt{\sum_{i=1}^n (u_i - v_i)^2} \quad (4.10)$$

onde u e v são os vetores produzidos pela representação LBP, e n corresponde ao comprimento do vetor.

4.1.5 Método usando *Scale-Invariant Feature Transform*

O *Scale-Invariant Feature Transform* (SIFT) proposto por Lowe [36] consiste em um método que extrai características relevantes em imagens que sejam razoavelmente invariáveis a mudanças de iluminação, ruído, rotação, escala e pequenas mudanças de perspectiva. Cada característica relevante ou *keypoint* é representado num vetor chamado de descritor contendo 128 valores, além de outras informações, como posicionamento e direção do gradiente. O SIFT é um dos mais populares descritores de imagens. Estes descritores podem ser utilizados para se fazer a correspondência de diferentes visões de um objeto ou cena. O algoritmo pode ser descrito em 4 etapas:

- **Detecção de extremos:** A primeira etapa da técnica SIFT consiste em buscar pontos que sejam invariantes a mudanças de escala e de orientação. Tal objetivo é alcançado empregando uma função DoG (*Difference of Gaussian*) para identificar os pontos de interesse.
- **Localização de características relevantes (*keypoints*):** Todos os pontos detectados como extremos são possíveis *keypoints*. Então são rejeitados aqueles pontos instáveis com baixo contraste, que seriam sensíveis a ruído e que ficam estáveis a mudanças de escala. Também são rejeitados nesta etapa pontos que fiquem em arestas.
- **Orientação de cada *keypoint*:** Nesta etapa é associada para cada *keypoint*, uma ou mais direções de acordo com os gradientes da imagem que se encontram ao redor do ponto referido. Também será calculada a magnitude do gradiente ao redor do mesmo ponto.
- **Descritor de cada *keypoint*:** O descritor é então criado computando-se as magnitudes e orientações dos gradientes que são amostradas ao redor da localização do *keypoint*.

Depois de extraídos os *keypoints* de duas imagens, são procurados pontos correspondentes em cada imagem, como exemplificado na Fig. 4.8. A comparação de pontos é baseada na similaridade dos descritores correspondentes. Os descritores são vetores que podem ser comparados, por exemplo, utilizando a distância Euclidiana. Normalmente, os candidatos à melhor correspondência são pontos próximos, de maneira que o melhor candidato é o ponto que apresenta a menor distância Euclidiana.

Lowe utilizou uma modificação do algoritmo Árvore k-d [58] chamado de método de *Best-Bin-First* (BBF) [59] que pode identificar os vizinhos mais próximos com elevada probabilidade. O problema da correspondência é reduzido à busca do vizinho mais próximo. No entanto, alguns pontos instáveis (*outliers*) são detectados ao longo do processo, levando a falsas correspondências. Para a eliminação desse problema, um método para comparar a menor distância com a menor segunda distância é usado, selecionando somente correspondentes próximos a um determinado limiar (*threshold*) [36].

O método SIFT, assim como o método LBP, foi utilizado em outros trabalhos [30, 31, 60] que aproveitam as características perioculares. Nesses trabalhos o SIFT foi fusionado junto com o LBP para melhorar o resultado do reconhecimento, mas os dois métodos empregavam somente características perioculares, sem aproveitar algum outro tipo de característica biométrica.

Representação

No procedimento anterior, usando o LBP, foi definida uma região em torno do olho, de onde foram extraídas as características. Neste método será usada a imagem toda. Primeiro a imagem foi convertida em tons de cinza em seguida foi usada a implementação mostrada em [61] para extrair os *keypoints*. A mesma implementação será empregada para fazer o casamento no procedimento de comparação descrito a seguir. Na Fig. 4.7 são mostradas a imagem original e a imagem convertida em tons de cinza com a localização dos *keypoints* usando círculos.

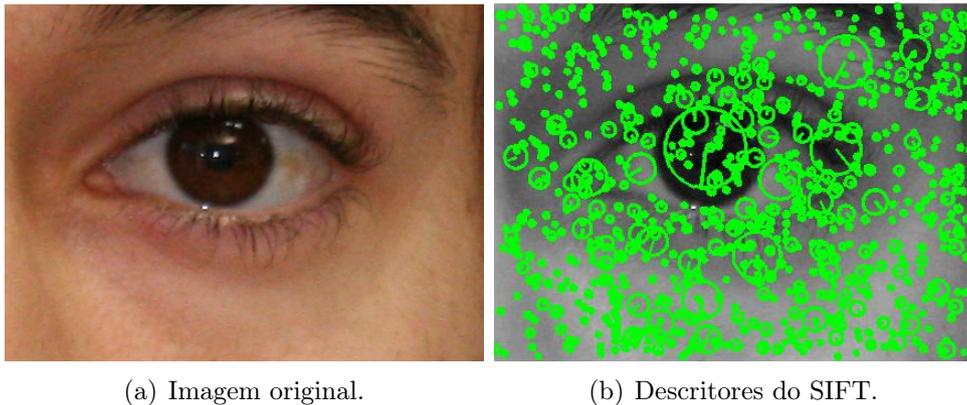
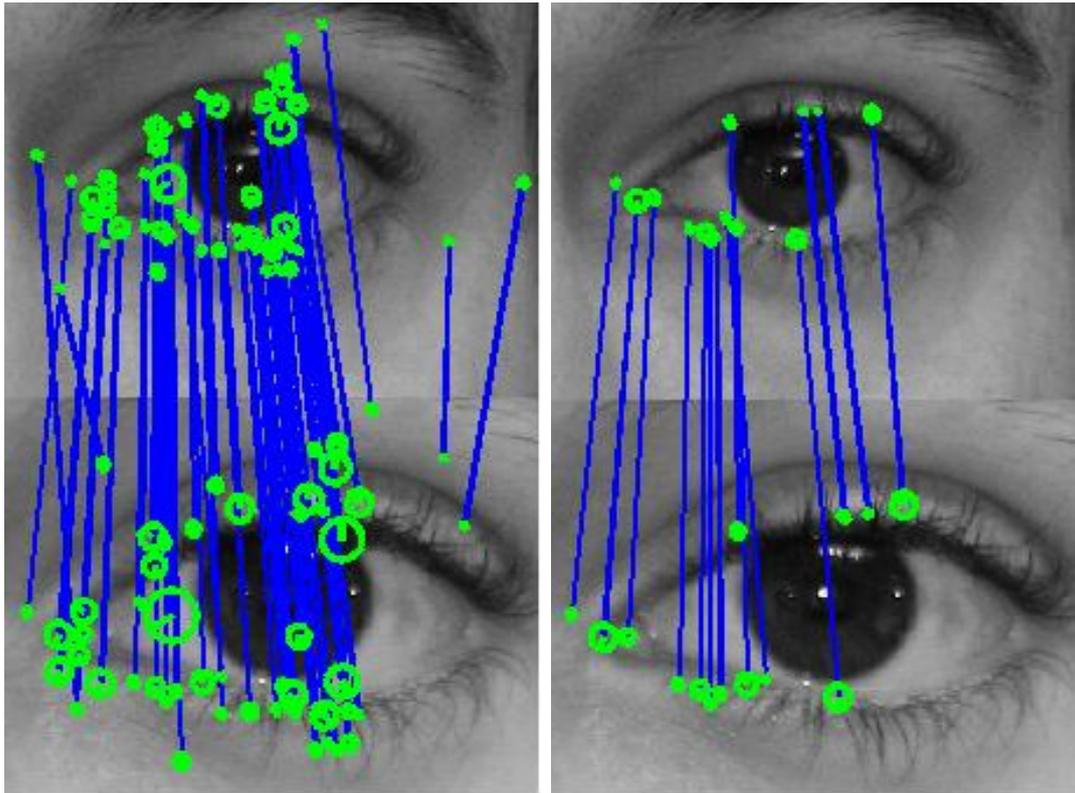


Figura 4.7: Procedimento da representação da imagem usando o SIFT.

Comparação

No processo de comparação entre duas imagens é realizado o casamento dos *keypoints* em duas imagens, empregando seus respectivos descritores. Cada casamento indica que as características na vizinhança dos *keypoints* casados são similares. Entretanto, pode acontecer que dois *keypoints* casados não correspondam à mesma região dos olhos comparados, como se pode observar no extremo direito da Fig. 4.8(a). Para evitar esse tipo de casamentos inválidos, foi calculada para cada casamento a distância entre as posições de seus respectivos *keypoints*. Em seguida foi determinada a distância que ocorreu com a maior frequência. Foram então considerados casamentos válidos aqueles que tinham a distância calculada entre seus descritores similar ao valor da distância com a maior frequência. Esta idéia é factível de ser implementada, porque a íris está localizada no centro da imagem. A distância Euclidiana dos *scores* [61] dos casamentos válidos foi usada para representar o resultado da comparação.

Na Fig. 4.8 é exemplificado graficamente o processo de casamento dos *keypoints*, onde cada casamento é representado por uma linha que liga dois círculos.



(a) Resultado da comparação.

(b) Eliminação dos *keypoints* invalidos.

Figura 4.8: Procedimento de comparação usando o SIFT.

4.1.6 Fusão dos métodos

O modelo da regressão logística [55, 62, 63] é empregado para descrever a relação entre as diferentes representações usadas neste trabalho e uma resposta final. Esta metodologia de ajuste de pesos foi usada em situações similares de fusão de métodos para o reconhecimento biométrico, usando classificadores de precisões diferentes [52, 64, 65].

A forma de proceder a regressão logística é equivalente a uma rede neural com uma saída e uma função de ativação logística. O modelo correspondente é descrito pela equação

$$\log\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_5x_5 \quad (4.11)$$

onde a fração $p/(1-p)$ é chamada de probabilidade de uma correspondência positiva, isto é, a relação entre a probabilidade e seu complemento [55], aplicados aos valores $x_j, j = 1, 2, \dots, 5$, produzidos pelos 5 métodos apresentados nesta seção. Os valores β_j representam os pesos para cada um dos métodos, e o peso β_0 representa um offset.

Para obter os pesos da Eq. (4.11) foram utilizadas 500 das 1.000 imagens do

banco UBIRIS.v2 fornecidas pelos organizadores da competição, e as outras 500 imagens foram separadas para os teste de desempenho. Para cada imagem foram extraídas suas respectivas representações para cada um dos 5 métodos empregados. Depois foram criadas as 124.750 combinações possíveis, onde cada vetor x_j contém o resultado da comparação entre todas as combinações, para cada método empregado. As combinações criaram comparações *inter-class* (usuários diferentes) e *intra-class* (mesmo usuário), onde 0 representa o resultado perfeito para uma comparação *inter-class*, e 1 o resultado perfeito para uma comparação *intra-class*.

Finalmente foram obtidos os valores para os pesos da função que vai devolver resultado final (R_f) da comparação entre duas imagens:

$$R_f = -14,06 - 8,56x_1 - 6,38x_2 - 6,98x_3 - 13,04x_4 + 5,22x_5 \quad (4.12)$$

onde x_1 representa o valor da comparação usando o método que emprega o LBP, x_2 para o método que usa o SIFT, x_3 para o método que a wavelet 2-D Wavelet, x_4 para o método que a wavelet o 1-D Wavelet e o x_5 o método mapas de comparações.

4.2 Resultado dos testes de desempenho

Empregando a função que retorna o valor final da comparação entre duas imagens, realizamos os testes do desempenho no reconhecimento utilizando as 500 imagens do banco separadas anteriormente. Além da decidibilidade (DEC) e do *Equal Error Rate* (EER), utilizadas na avaliação do método proposto da normalização da íris no Capítulo 3, também serão aplicadas a curva do *Receiver Operating Characteristic* (ROC) e a curva *Cumulative Match Characteristic* (CMC).

A curva ROC é um gráfico da probabilidade de uma identificação correta, ou taxa de verdadeiros positivos, versus a taxa de falsos positivos ou probabilidade de um usuário ser rejeitado quando ele tinha que ser aceito. Além da visualização gráfica, as curvas ROC podem ser reduzidas a um valor escalar através da *Area Under Curve* (AUC), que representa a área sob a curva ROC. Como o espaço de ROC é um quadrado unitário, o valor 1 representaria um sistema que identifica perfeitamente os usuários.

As medidas EER, DEC, AUC e a curva ROC, são usados para avaliar um sistema em modo verificação ou um para um (1:1). Neste modo uma amostra biométrica é recolhida de uma pessoa; cuja identidade é submetida à validação. Conseqüentemente, este dado é comparado com o modelo previamente armazenado para a identidade reivindicada. Se o resultado da comparação for suficiente, a identidade reivindicada é verificada, e se a imagem de prova e o modelo não combinarem o suficiente, a reivindicação é rejeitada.

Para avaliar um sistema em modo identificação ou um para todos (1:N), uma amostra biométrica é recolhida de uma pessoa, e é então comparada com o modelo de cada indivíduo previamente registrado no banco de dados. De acordo com o valor da medida de similaridade obtida a cada comparação, o sistema deve determinar a identidade da pessoa. O sistema retorna para cada pessoa uma lista com os valores de similaridade ordenadas da menor para a maior, onde a identificação correta da amostra se encontra numa determinada posição ou Rank. Um sistema de reconhecimento eficaz, a correta identificação deve-se encontrar na primeira posição ou Rank-1. A curva CMC apresenta a probabilidade de que o sistema faça um correta identificação numa determinada posição n Rank- n .

Na Tabela 4.1 são mostradas as medidas da performance de cada método e da fusão de todos eles. A fusão melhora o desempenho final do sistema com respeito aos valores obtidos pelos métodos individualmente, pois obtém os maiores índices DEC e AUC e o menor EER, produzindo um incremento de 17,2% na DEC com respeito ao melhor método individual. Em relação ao EER, a fusão diminuiu 20,1% a taxa do erro, e o AUC aumentou 5,9%. Seguindo da fusão, o método que usa a wavelet de uma dimensão alcança a melhor performance dentre os métodos individuais, e no outro extremo as técnicas periculares são as que mostram o pior desempenho. O método que utiliza o LBP apresenta um melhor desempenho com respeito ao SIFT nas três medidas mostradas.

Tabela 4.1: Valores da performance do Reconhecimento.

| | DEC | EER(%) | AUC |
|----------------------|------|--------|------|
| LBP | 0.99 | 31.87 | 0.76 |
| SIFT | 0.87 | 32.09 | 0.74 |
| 1-D Wavelet | 1.44 | 23.12 | 0.85 |
| 2-D Wavelet | 1.29 | 25.04 | 0.82 |
| Mapas de Comparações | 1.27 | 24.99 | 0.82 |
| Fusão | 1.74 | 18.48 | 0.90 |

Na Fig. 4.9 são mostradas as curvas ROC para cada método individual e para a fusão. Observando as curvas dos métodos individuais conclui-se que o método mapa das comparações tem sua curva mais próxima do eixo vertical, o que indica uma maior sensibilidade na detecção dos verdadeiros positivos com uma taxa menor de falsos positivos. A curva que representa a fusão dos métodos mostra um melhor desempenho, pois aproxima-se mais do eixo vertical, conseguindo uma maior taxa de verdadeiros positivos e mantendo baixa a taxa dos falsos positivos.

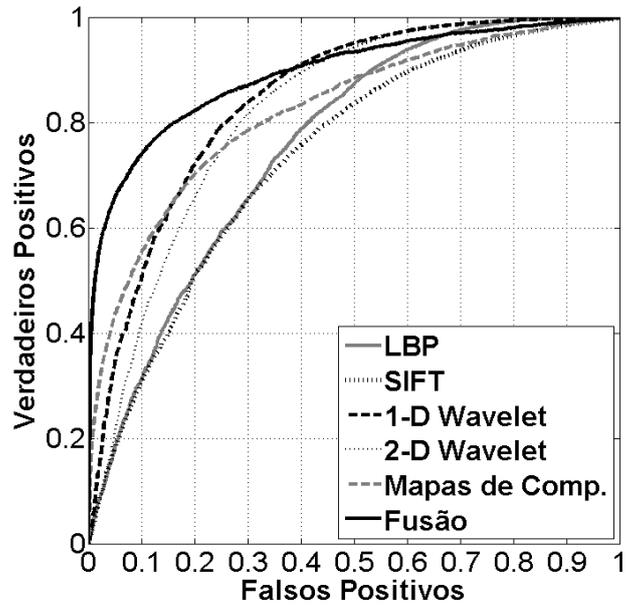


Figura 4.9: Curvas ROC obtidas pela fusão e por cada método.

No modo identificação, os resultados da fusão mostrados na Fig. 4.10 confirmam o aumento na performance da fusão em comparação com cada um dos métodos. Observando o resultado do Rank-1 a fusão mostrou 74.3% de acerto e o melhor resultado individual foi de 56,4%, uma melhoria de 31,7%. É interessante observar que a performance obtida pelo método que usa o LBP foi superior à dos outros métodos usados. Essa performance foi obtida devido ao fato de que o método focaliza uma região próxima do olho, como foi ilustrado na Fig. 4.6. A região usada pelo LBP tem uma menor variação quando o olho é capturado em diferentes poses, tornando o método robusto ao procurar a imagem com maior semelhança.

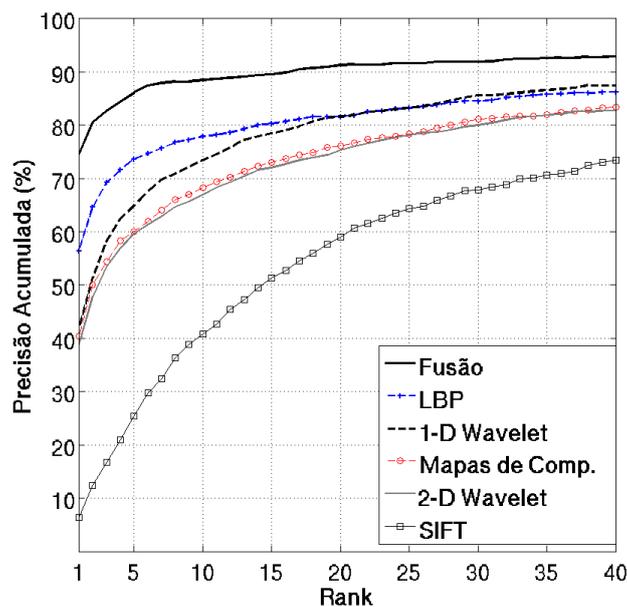


Figura 4.10: Curvas CMC obtidas pela fusão e por cada método.

O método SIFT utiliza uma maior área da imagem para extrair as características em relação aos outros métodos usados, pois usa a imagem toda. Como consequência é mais afetado quando existem grandes variações nas condições de aquisição da imagem (iluminação, pose, etc). Na Fig. 4.11 é mostrado um exemplo de aquisição de uma imagem do mesmo olho, do mesmo usuário, mas com um ângulo de captura diferente.



Figura 4.11: Exemplo de aquisição de imagens de olhos do mesmo usuário.

O fato do olho não ser uma superfície plana, pode ter comprometido ainda mais o desempenho do SIFT quando existem variações acentuadas de perspectiva. Uma mudança de perspectiva num objeto 3D pode fazer com que ele apresente uma forma diferente para um mesmo ponto fixo de referência.

O desempenho do SIFT em imagens com diferentes perspectivas foi o mesmo que obtivemos no trabalho apresentado em [66]. Nesse trabalho ainda que a característica biométrica explorada tenha sido a das orelhas, o SIFT apresentou um comportamento semelhante ao observado no caso da íris quando existe uma mudança de perspectiva. O experimento consistiu de capturas de imagens das orelhas dos usuários movimentando a cabeça com movimentos ascendentes, descendentes, em direção da câmera e na direção oposta. As imagens sem rotação foram comparadas com as imagens em que o usuário mudou de pose. Na Fig. 4.12 são mostradas as diferentes poses usadas no experimento. É fácil perceber, nessas imagens, que a forma da orelha muda notoriamente quando o usuário mira na direção da câmera, ou quando gira a cabeça em direção oposta. Essa mudança da forma afetou em maior grau o desempenho no reconhecimento do SIFT, em comparação com as imagens que tinham movimentos ascendentes ou descendentes.

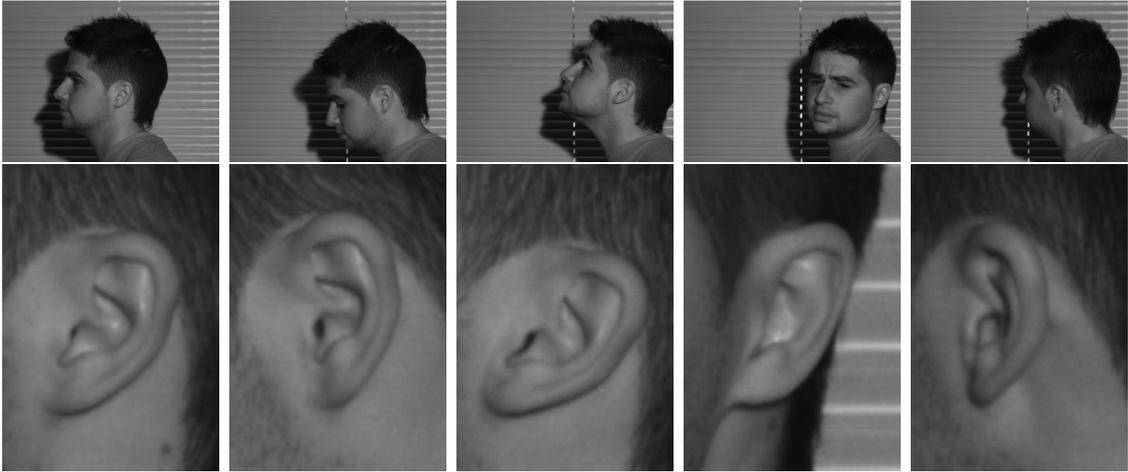


Figura 4.12: Imagens do banco UBEAR (parte superior), e região em torno a orelha (parte inferior).

No *Noisy Iris Challenge Evaluation - Part 2* foram quase 70 participantes de diferentes países, e como medida da avaliação para determinar as melhores propostas de reconhecimento biométrico foi empregada a decidibilidade. A proposta apresentada neste Capítulo conseguiu o terceiro lugar da competição NICE.II [34] obtendo um valor de 1,77 perto dos 1,74 relatado na Tabela 4.1, mostrando a robustez da proposta. O primeiro lugar foi conseguido pelo pessoal do laboratório da CASIA com um valor de 2,34, seguido por o *Techshino Biometrics Research Center* com uma decidibilidade de 1,86. Devido à quantidade e qualidade dos participantes envolvidos na competição, o resultado da proposta a torna um aporte interessante que poderia ser utilizado como base de sistemas biométricos multimodais.

Capítulo 5

Identificação de indivíduos usando imagens capturadas com cooperação

No capítulo anterior foi explicado que as imagens do banco UBIRIS.v2, poderiam ser tratadas como imagens de um sistema de reconhecimento onde os usuários não cooperavam durante o processo de captura. Também foi dito que majoritariamente sistemas de reconhecimento cobram do usuário certo grau de cooperação, e no caso de sistemas de reconhecimento biométrico que utilizam a íris a grau de cooperação é um pouco maior. Isto é devido a que a íris é um alvo pequeno, e o usuário tem que fixar a mirada, para que seja obtida uma imagem que apresente os detalhes da íris com qualidade.

Neste capítulo será simulado um sistema de reconhecimento baseado na íris e na região periocular, onde o usuário presta certa grau de cooperação no momento da captura das imagens. Para isso as imagens das versões *Lamp* e *Thousand* do banco de CASIA [46] foram empregadas. Além dos usuários cooperar em no momento da captura, as duas versões apresentam características similares. Ambas foram capturadas empregando luz infravermelha, utilizando a mesma distância entre o usuário e a câmera, e em todas as imagens a íris foi capturada em conjunto com a região periocular. A versão *Lamp* apresenta imagens com diferentes graus de ocultação da íris, devido aos cílios ou às pálpebras. Já a versão *Thousand* contem usuários com óculos que degradam a captura dos detalhes da íris e apresentam reflexos especulares. Esses problemas encontrados para capturar toda a região da íris com uma boa qualidade, faz com que um sistema de reconhecimento baseado só na íris tenha sua performance diminuída. Para compensar em parte a perda de desempenho no reconhecimento é possível aproveitar as características periorculares.

A proposta do sistema biométrico multimodal do Capítulo 4 foi analisada do ponto de vista de conseguir a melhor performance, especificamente com respeito à decidibilidade que foi a medida para avaliar o melhor desempenho das propostas participantes na competição. Conseguir num sistema de alta segurança, um aumento

de 5% na performance do reconhecimento empregando uma maior quantidade de métodos, pode ser suficiente para que o tempo que possa demorar a identificação do usuário não seja um fator determinante. Os sistemas de alta segurança são colocados principalmente em lugares onde a movimentação das pessoas é pouca ou restrita, mas na entrada de um prédio onde a movimentação das pessoas é maior, pode-se dar o caso onde é possível sacrificar um pouco a exatidão do reconhecimento, para utilizar um método que permita uma maior fluidez das pessoas.

Na Tabela 4.1 no capítulo anterior foi mostrado o incremento do desempenho no reconhecimento da fusão dos métodos com respeito ao melhor desempenho dos métodos individuais. A Tabela 5.1 apresenta o desempenho de outras fusões além da fusão de todos os métodos que empregam a íris. O desempenho é mostrado usando a decidibilidade (DEC), o *Equal Error Rate* (EER) e a *Area Under Curve* (AUC). Cada fusão foi realizada empregando a regressão logística, como foi explicado no Capítulo 4.

No capítulo anterior os métodos que empregaram a íris tiveram os melhores resultados individuais, mas quando foram fusionados mostraram um menor desempenho com respeito a algumas fusões que utilizam informação periocular e da íris, como pode ser observado nos resultados da Tabela 5.1. Os métodos utilizados nesta pesquisa mostram um melhor resultado quando são fusionados criando sistemas multimodais. A fusão utilizando somente métodos periorculares não foi tomada em conta devido a que individualmente tiveram um desempenho bem menor.

Das fusões apresentadas na Tabela 5.1, o método 1-D Wavelet obteve o melhor resultado ao ser fusionado com os métodos periorculares, seguido do método 2-D Wavelet e do mapa de comparações. Devido a isso foi fusionado com respeito a cada um dos métodos periorculares, resultando que a fusão com o SIFT teve um desempenho um pouco melhor. A diferença do desempenho entre essas duas fusões é pouco significativo, mas devemos lembrar que o SIFT foi o método que apresentou o pior desempenho de todos os métodos, em cada uma das avaliações realizadas no Capítulo 4.

Tabela 5.1: Performance das fusões.

| | DEC | EER(%) | AUC |
|-------------------------------------|------|--------|------|
| 1-D Wav. – 2-D Wav. – Map. de Comp. | 1,56 | 20,80 | 0,87 |
| LBP – SIFT – 1-D Wavelet | 1,66 | 20,23 | 0,88 |
| LBP – SIFT – 2-D Wavelet | 1,61 | 20,62 | 0,87 |
| LBP – SIFT – Map. de Comp. | 1,52 | 22,02 | 0,86 |
| 1-D Wavelet – SIFT | 1,57 | 21,14 | 0,86 |
| 1-D Wavelet – LBP | 1,56 | 21,78 | 0,86 |

Além da avaliação no modo verificação (1:1) utilizando as medidas DEC, EER

e AUC mostradas na Tabela 5.1, realizamos testes de avaliação no modo identificação (1:N) empregando a *Cumulative Match Characteristic* (CMC) nas mesmas fusões multimodais. A Figura 5.1 apresenta as curvas das fusões dos métodos perioculares com cada método que emprega a íris, onde a fusão do método 1-D Wavelet em conjunto com os métodos perioculares mostra um melhor desempenho ao conseguir uma maior probabilidade no Rank1. As curvas CMC das fusões do método 1-D Wavelet com os métodos perioculares são mostrados na Fig. 5.2, onde o melhor desempenho no Rank1 foi obtido pela fusão dos métodos SIFT e 1-D Wavelet.

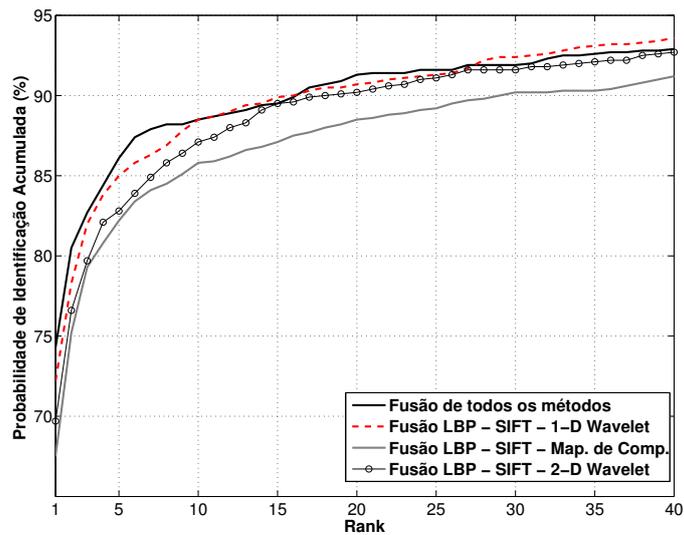


Figura 5.1: Curvas CMC da fusão dos métodos perioculares com cada método que utiliza a íris.

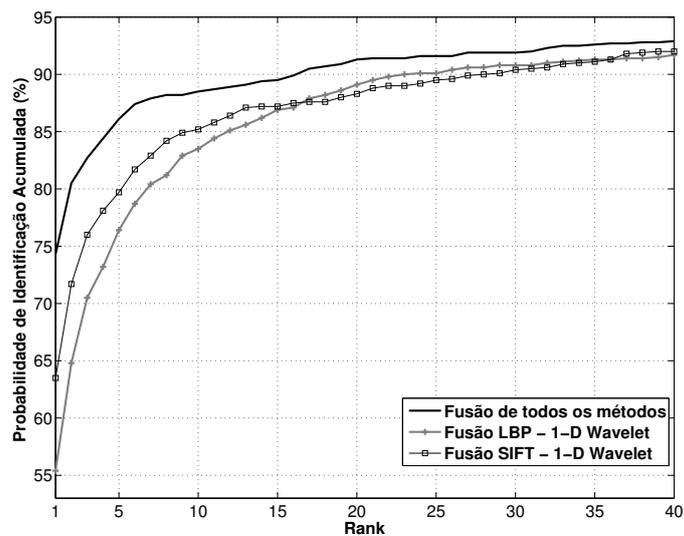


Figura 5.2: Curvas CMC da fusão do método 1-D Wavelet com cada método periocular.

Segundo os resultados obtidos, decidimos empregar somente o método

1-D Wavelet e o SIFT para criar um sistema biométrico multimodal para imagens capturadas com cooperação dos usuários. O SIFT teve o pior desempenho de reconhecimento nas imagens do banco UBIRIS.v2, e foi explicado que um dos maiores problemas foram as mudanças fortes de pose encontradas nas imagens. Nas imagens do banco de CASIA ao serem capturadas com cooperação dos usuários, não foram encontradas mudanças de pose significativas, o que possibilita a implementação de certas restrições para melhorar o resultado do SIFT, que serão detalhadas posteriormente. Essas restrições criadas puderam ser aproveitadas para desenvolver um novo método de reconhecimento baseado também no SIFT, mas que utilizam a imagem da íris normalizada para identificar os usuários. Então este sistema emprega dois métodos que aproveitam os detalhes da íris e outro que aproveita as características perioculares.

O método de normalização da íris que vai ser utilizado neste capítulo será a nossa proposta apresentada no Capítulo 3. As 20.000 imagens das duas versões do banco CASIA usadas neste capítulo, criaram uma quantidade muito elevada de combinações possíveis que foram usadas nos testes de avaliação de desempenho. Isso sem contar que os testes são repetidos muitas vezes ao longo da pesquisa. Como foi indicado, nossa proposta de normalização faz com que o desempenho do reconhecimento diminua, e então é possível implementar o método de normalização de Daugman para uma versão final do sistema, se o tempo no processo de identificação não for um fator determinante.

Em seguida são detalhados os métodos empregados para um sistema biométrico multimodal que emprega imagens capturadas com a cooperação dos usuários. Na última seção serão mostrados os resultados do desempenho do sistema.

5.1 Sistema biométrico multimodal para imagens capturadas com cooperação dos usuários

O procedimento do sistema é iniciado pela segmentação da região da íris. Para isso são necessárias as localizações da pupila e da borda externa da íris, assim como as localizações das pálpebras e dos cílios. Este procedimento foi descrito em detalhes no Capítulo 2. Em seguida são extraídas as características da íris e da região periocular usando os métodos já indicados, posteriormente a etapa de comparação, e finalmente a determinação do resultado gerado pela fusão dos métodos. O procedimento é apresentado na Fig. 5.3 e os métodos que utilizam o SIFT são descritos em detalhes nas seções seguintes, o método 1-D Wavelet será o mesmo detalhado no capítulo anterior.

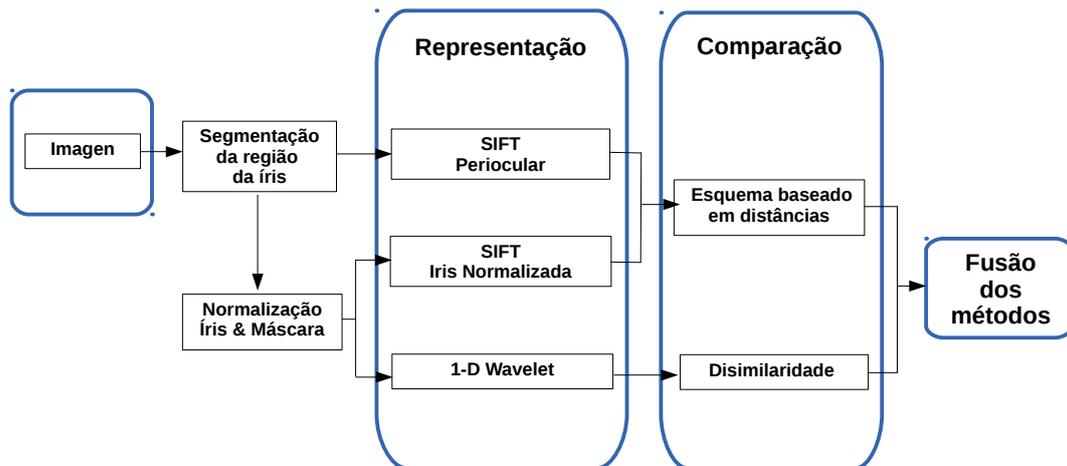


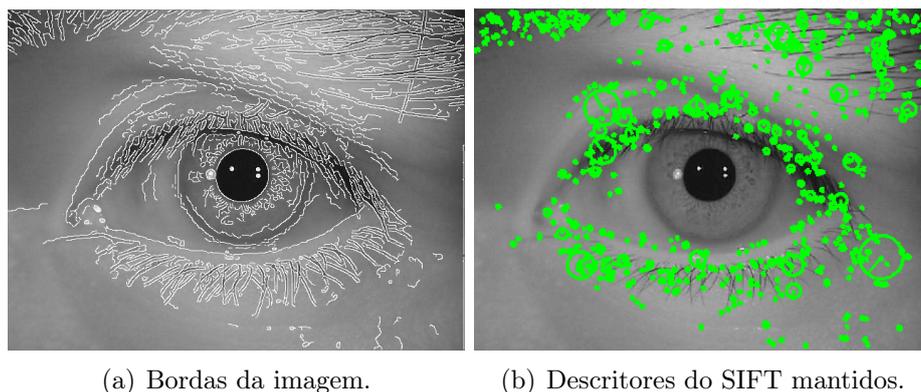
Figura 5.3: Metodologia proposta para imagens capturadas com luz infravermelha.

5.1.1 SIFT na região periocular

O uso do SIFT na região periocular nas imagens do banco CASIA terá algumas mudanças com respeito ao uso nas imagens da UBIRIS.v2, principalmente para aproveitar características encontradas nas imagens do CASIA, como por exemplo a não mudança de pose nas imagens capturadas. O procedimento para extrair as características que representam a região periocular e o modo como é feita a comparação serão descritos a seguir.

Representação

Utilizando a implementação do SIFT [61] os *keypoints* foram extraídos da imagem, e foram descartados aqueles localizados no interior da região visível da íris. Isso foi devido às mudanças fortes da dilatação da pupila observadas nas imagens do banco CASIA, que fazem com que as formas dos detalhes da íris de um mesmo usuário mudem de uma imagem para outra. Foi observado também que na região em torno do olho existem zonas que não contêm informação relevante que ajude a discriminar duas imagens, como por exemplo aquelas que contêm pouca textura ou que são muito suavizadas. Para evitar zonas de pouco interesse, mantivemos os *keypoints* extraídos localizados perto das bordas. Além de indicar mudanças de textura, as bordas evidenciam características relevantes, como sobrancelhas, cílios, limites da pupila, da íris e das pálpebras. As bordas foram localizadas utilizando o operador de Canny. Nas Figs. 5.4(a) e 5.4(b), são mostradas as imagens indicando as bordas após aplicar o operador de Canny e os *keypoints* mantidos.



(a) Bordas da imagem.

(b) Descritores do SIFT mantidos.

Figura 5.4: Descritores do SIFT mantidos por ficarem perto das bordas da imagem.

Comparação

Para determinar se um casamento entre dois *keypoints* de duas imagens é válido, utilizamos as características que foram encontradas nas imagens das duas versões do banco CASIA. Primeiro notou-se que as imagens foram capturadas a distâncias similares, e portanto os tamanhos dos olhos dos usuários têm pouca variação. A rotação entre olhos da mesma pessoa é mínima, mas a posição pode variar de um modo significativo, como mostrado na Fig. 5.5.

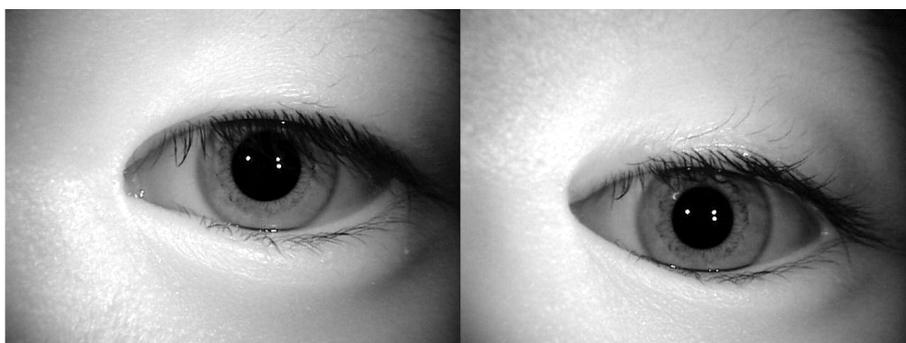


Figura 5.5: Imagens de olhos do mesmo usuário: os olhos têm tamanhos similares, não existe quase rotação entre eles, mas têm posições diferentes.

Nas Figs. 5.6 e 5.7 são mostrados o procedimento e o resultado obtido com a implementação [61] do método SIFT, para uma confrontação com olhos do mesmo usuário e de usuários diferentes, respectivamente. Utilizando os descritores dos *keypoints* extraídos na etapa de representação, é feito o casamento. Depois, no processo de depuração, os *keypoints* do mesmo casamento que tenham magnitude e orientação diferentes são descartados. Além de usar a magnitude e a orientação para manter casamentos válidos, são também mantidos aqueles que em sua maioria tenham o mesmo ângulo de inclinação, da reta formada entre os pontos de localização dos *keypoints* de um mesmo casamento. No caso de não existir maioria, por exemplo quando todos os casamentos têm diferentes inclinações, são descartados

todos os casamentos. Finalmente, foi usada a distância Euclidiana dos *scores* [61] dos casamentos resultantes para determinar a similaridade entre dois olhos.

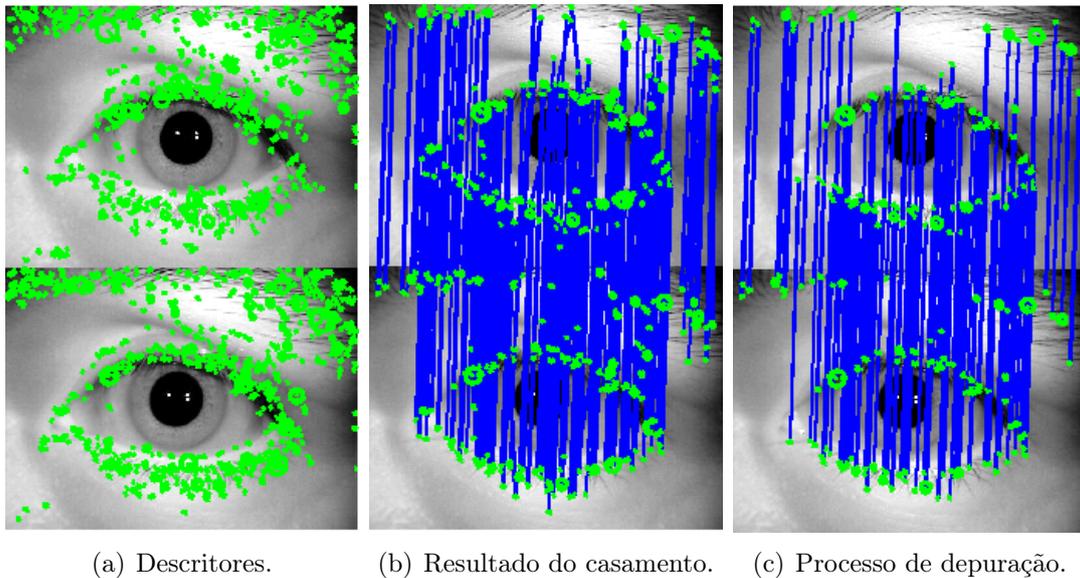


Figura 5.6: Procedimento do SIFT em olhos iguais.

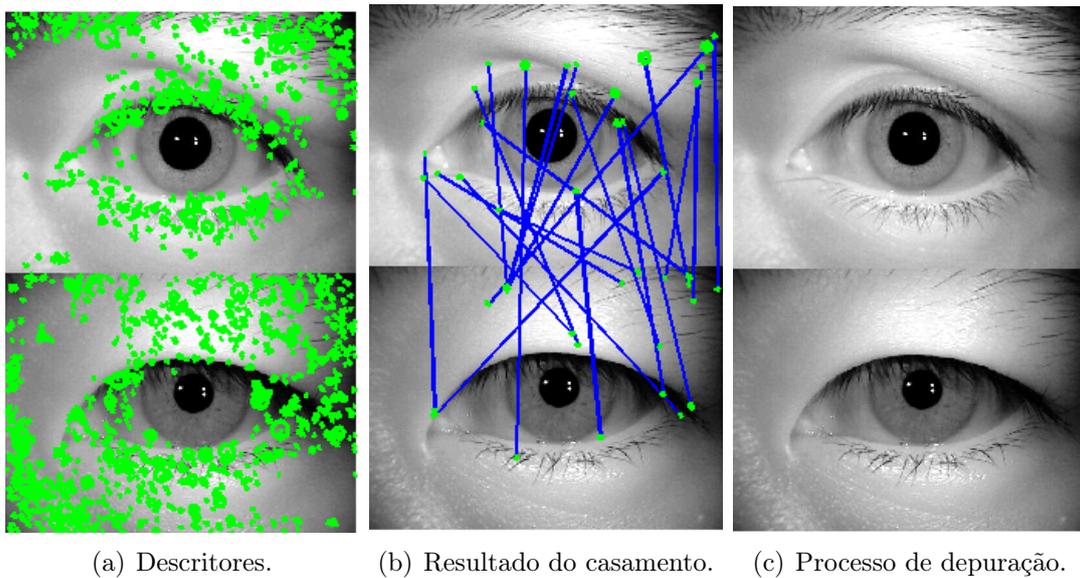


Figura 5.7: Procedimento do SIFT em olhos diferentes.

5.1.2 SIFT na imagem da íris normalizada

O método SIFT foi usado em outros trabalhos para identificação de pessoas usando somente a região da íris. O principal problema desta metodologia é que os trabalhos encontrados em nossa pesquisa [67], [68] e [69] mostram resultados com a região da íris não normalizada, e são citadas as vantagens de não precisar aplicar o procedimento de normalização. O argumento é válido em parte. A idéia de não precisar da

normalização da região da íris só é válida em sistemas que contenham um controle da luminosidade do ambiente. A região da íris é deformada pela dilatação ou contração da pupila devido à luz que nela incide, como mostrado na Fig. 5.8. Então a íris é normalizada utilizando a proposta apresentada no Capítulo 3. Em seguida são apresentados os procedimentos de representação e comparação para a identificação das imagens normalizadas utilizando o SIFT.



Figura 5.8: Imagens do mesmo usuário com diferentes dilatações da pupila.

Representação

O procedimento para extrair as características da íris normalizada usando o SIFT é composto pelas seguintes etapas, mostradas graficamente na Fig. 5.9:

- A região da íris é normalizada numa imagem de 40×512 e realçada empregando a equalização do histograma das intensidades dos pixels da imagem;
- São extraídos os *keypoints* usando a implementação [61] do SIFT;
- Utilizando a máscara da região da oclusão causada pelas pálpebras e cílios, são mantidos os *keypoints* localizados na região da íris não oculta.



(a) Descritores extraídos pelo SIFT.



(b) Máscara da região da oclusão.



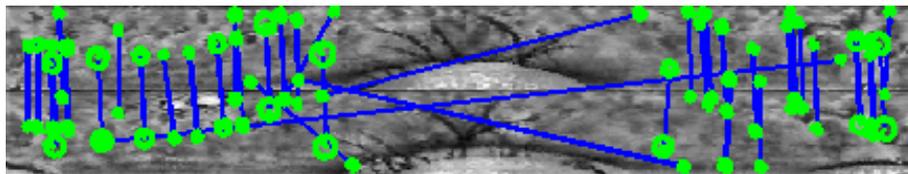
(c) Descritores do SIFT localizados na região da íris visível.

Figura 5.9: Procedimento de extração das características da íris normalizada usando o SIFT.

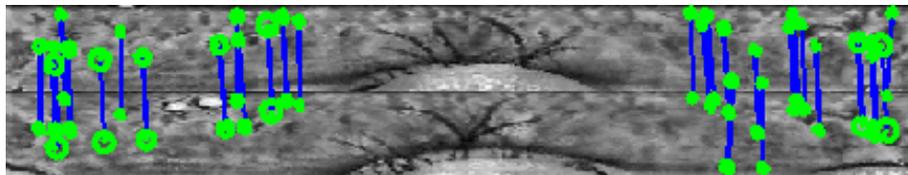
Comparação

A primeira característica a ser observada nas imagens normalizadas está na localização dos *keypoints* correspondentes a um mesmo casamento. Se as imagens correspondem ao mesmo usuário, os *keypoints* têm que estar localizados quase na mesma coordenada em cada imagem das íris normalizadas. Se os pontos encontram-se em posições afastadas, estes serão considerados pontos de um casamento não válido, sendo portanto eliminados. A magnitude e orientação dos *keypoints* dos casamentos restantes são comparadas mantendo aqueles com valores similares. Se depois do procedimento de eliminação dos casamentos não validos, existisse no final só um casamento, este é apagado. O procedimento detalhado é mostrado graficamente na Fig. 5.10 para o caso de uma comparação com imagens do mesmo usuário, e na Fig. 5.11 é mostrada uma comparação de imagens de diferentes usuários.

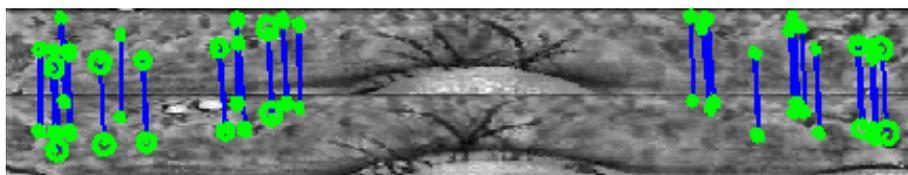
Finalmente, foi usada a distância Euclidiana dos *scores* [61] dos casamentos resultantes para determinar a similaridade entre duas imagens normalizadas.



(a) Resultado do casamento correspondente entre duas imagens.

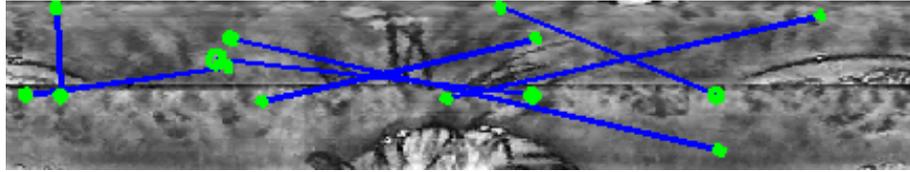


(b) Eliminação de casamentos segundo a localização.

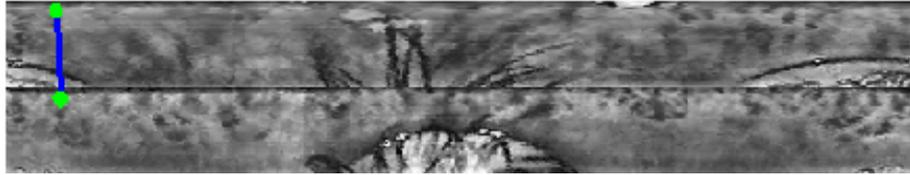


(c) Resultado final após descartar casamentos com orientações ou magnitudes diferentes.

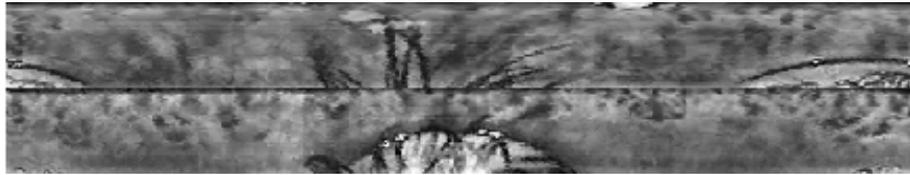
Figura 5.10: Comparação entre duas imagens do mesmo usuário usando o SIFT.



(a) Resultado do casamento correspondente entre duas imagens.



(b) Eliminação de casamentos não válidos.



(c) Se no final resta um só casamento, este é descartado.

Figura 5.11: Comparação entre duas imagens de usuários diferentes usando o SIFT.

5.1.3 Fusão dos métodos

Como serão utilizadas duas versões do banco CASIA com características diferentes para a avaliação do desempenho, é necessário aplicar o modelo da regressão logística para cada conjunto de teste de cada versão (*Lamp* e *Thousand*). Os conjuntos de testes estão formados por 500 imagens de cada versão escolhidas aleatoriamente do total de imagens. Será usado o procedimento detalhado na Seção 4.1.6 do capítulo anterior, ou seja foram obtidos os valores para os pesos da função que fornece o resultado final da comparação entre duas imagens para cada versão do banco de CASIA.

Para a versão *Lamp* (R_L) e para a versão *Thousand* (R_T) as funções são descritas por:

$$R_L = -48,9 - 8,3x_1 + 65,4x_2 - 11,5x_3 \quad (5.1)$$

$$R_T = -34,7 - 11,9x_1 + 30,6x_2 - 15,5x_3 \quad (5.2)$$

onde x_1 representa o valor da comparação usando o método que emprega o SIFT na região periocular, x_2 para o método que usa o wavelet 1-D e o x_3 para o método que utiliza o SIFT na imagem da íris normalizada.

5.2 Resultados dos testes do desempenho

Empregando as funções que retornam o valor final da comparação entre duas imagens para cada uma das versões do banco de CASIA (Eqs. (5.1) e (5.2)), foram realizados os testes de desempenho para a fusão apresentada neste capítulo. Os subconjuntos foram os empregados para a avaliação dos métodos da normalização da íris no Capítulo 3. Para a avaliação do desempenho foram eleitos o *Receiver Operating Characteristic* (ROC), *Area Under Curve* (AUC), *Equal Error Rate* (EER) e a decidibilidade (DEC). Nas Figs. 5.12 e 5.13 são mostrados os valores obtidos em cada medida de avaliação para cada versão do banco CASIA. Além de mostrar o desempenho da fusão descrita neste capítulo, as Figs. apresentam o desempenho para cada método avaliado individualmente e para outras fusões testadas.

IrisWav se refere ao método que emprega a wavelet 1-D Wavelet na íris normalizada, **Peri** ao método que aproveita as características perioculares e o **IrisSift** corresponde ao método que utiliza o SIFT para aproveitar as características da íris na imagem normalizada. As combinações das siglas detalhadas representam a fusão dos métodos que representam. As fusões **Peri–IrisWav** e **Peri–IrisSift** foram obtidas empregando o procedimento para obter a fusão **Peri–IrisSift–IrisWav** explicado na seção anterior.

Focalizando a análise nos métodos individuais, o método **IrisWav** mostrou o melhor desempenho nas duas versões do banco CASIA, diminuindo seu desempenho na versão *Thousand* devido ao fato de que os usuários usavam óculos na captura das imagens. O método **Peri** apresentou o comportamento com menor variação do desempenho nas duas versões do banco e, como aconteceu com o método **IrisWav**, teve uma diminuição na versão *Thousand*. Já o método **IrisSift** na versão *Lamp* teve uma performance semelhante à método **IrisWav**, mas na versão *Thousand* sua performance foi muito reduzida, apresentando o pior resultado no EER e no AUC. Os resultados indicam que o SIFT é mais afetado pelo ruído causado pelos óculos dos usuários nos detalhes da íris a serem extraídos.

Analisando os métodos multimodais a fusão **Peri–IrisSift** teve o pior desempenho nas duas versões do banco CASIA, com respeito às fusões testadas. A fusão **Peri–IrisWav** teve um desempenho próximo ao de fusão **Peri–IrisSift–IrisWav** na versão *Lamp*, diminuindo a diferença na versão *Thousand* devido à perda do desempenho do método **IrisSift**.

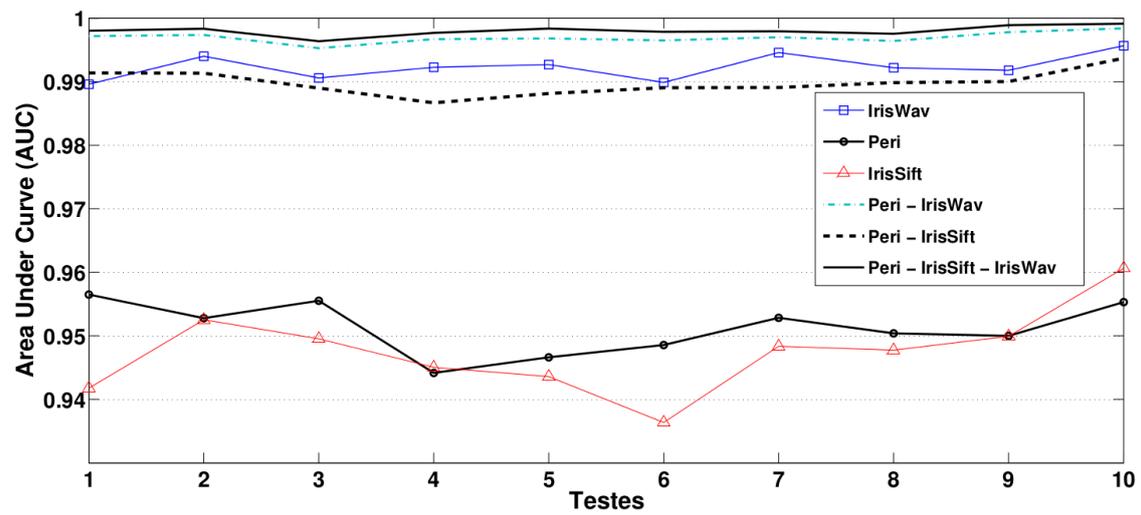
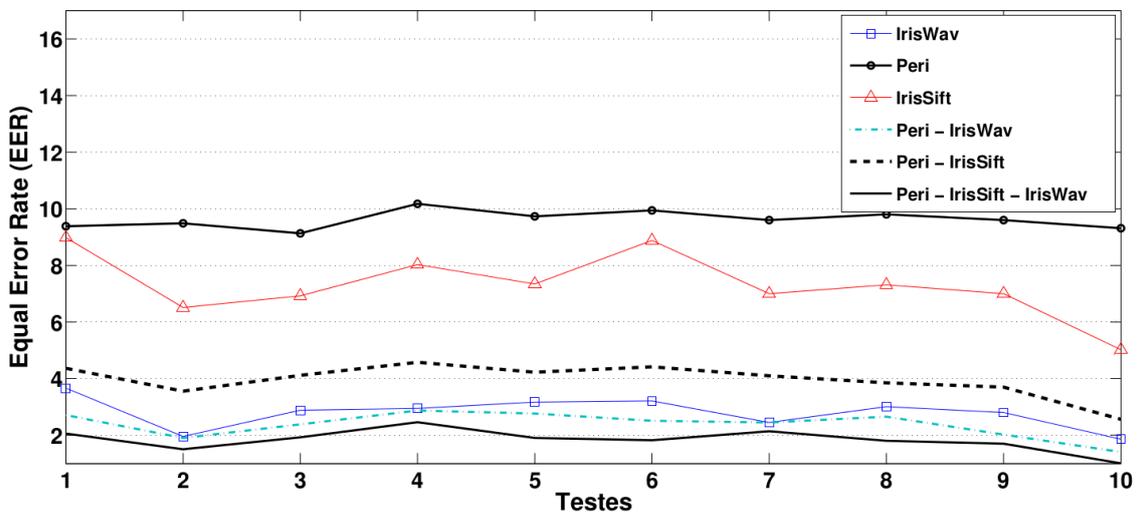
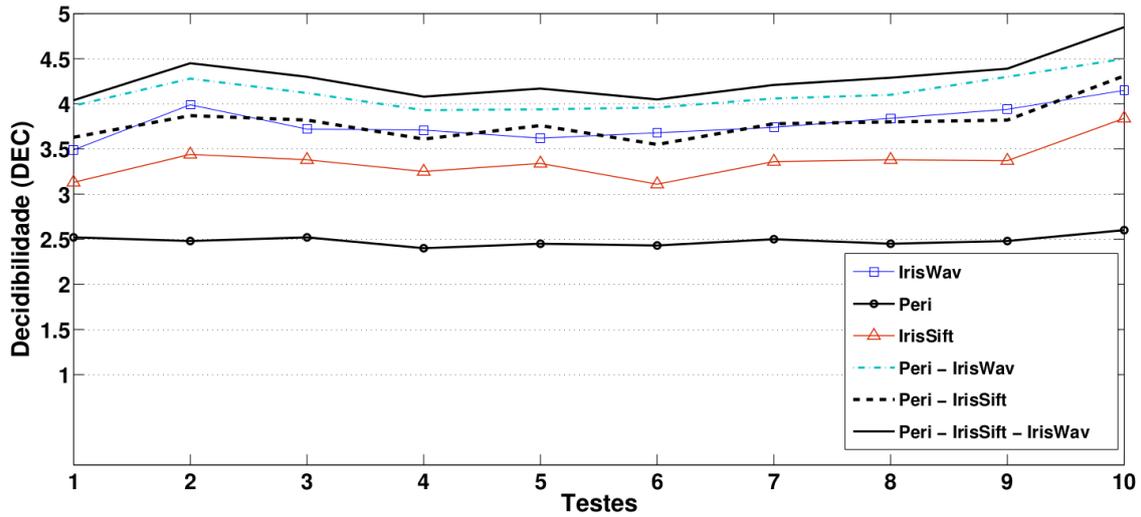


Figura 5.12: Testes de desempenho utilizando a versão Lamp.

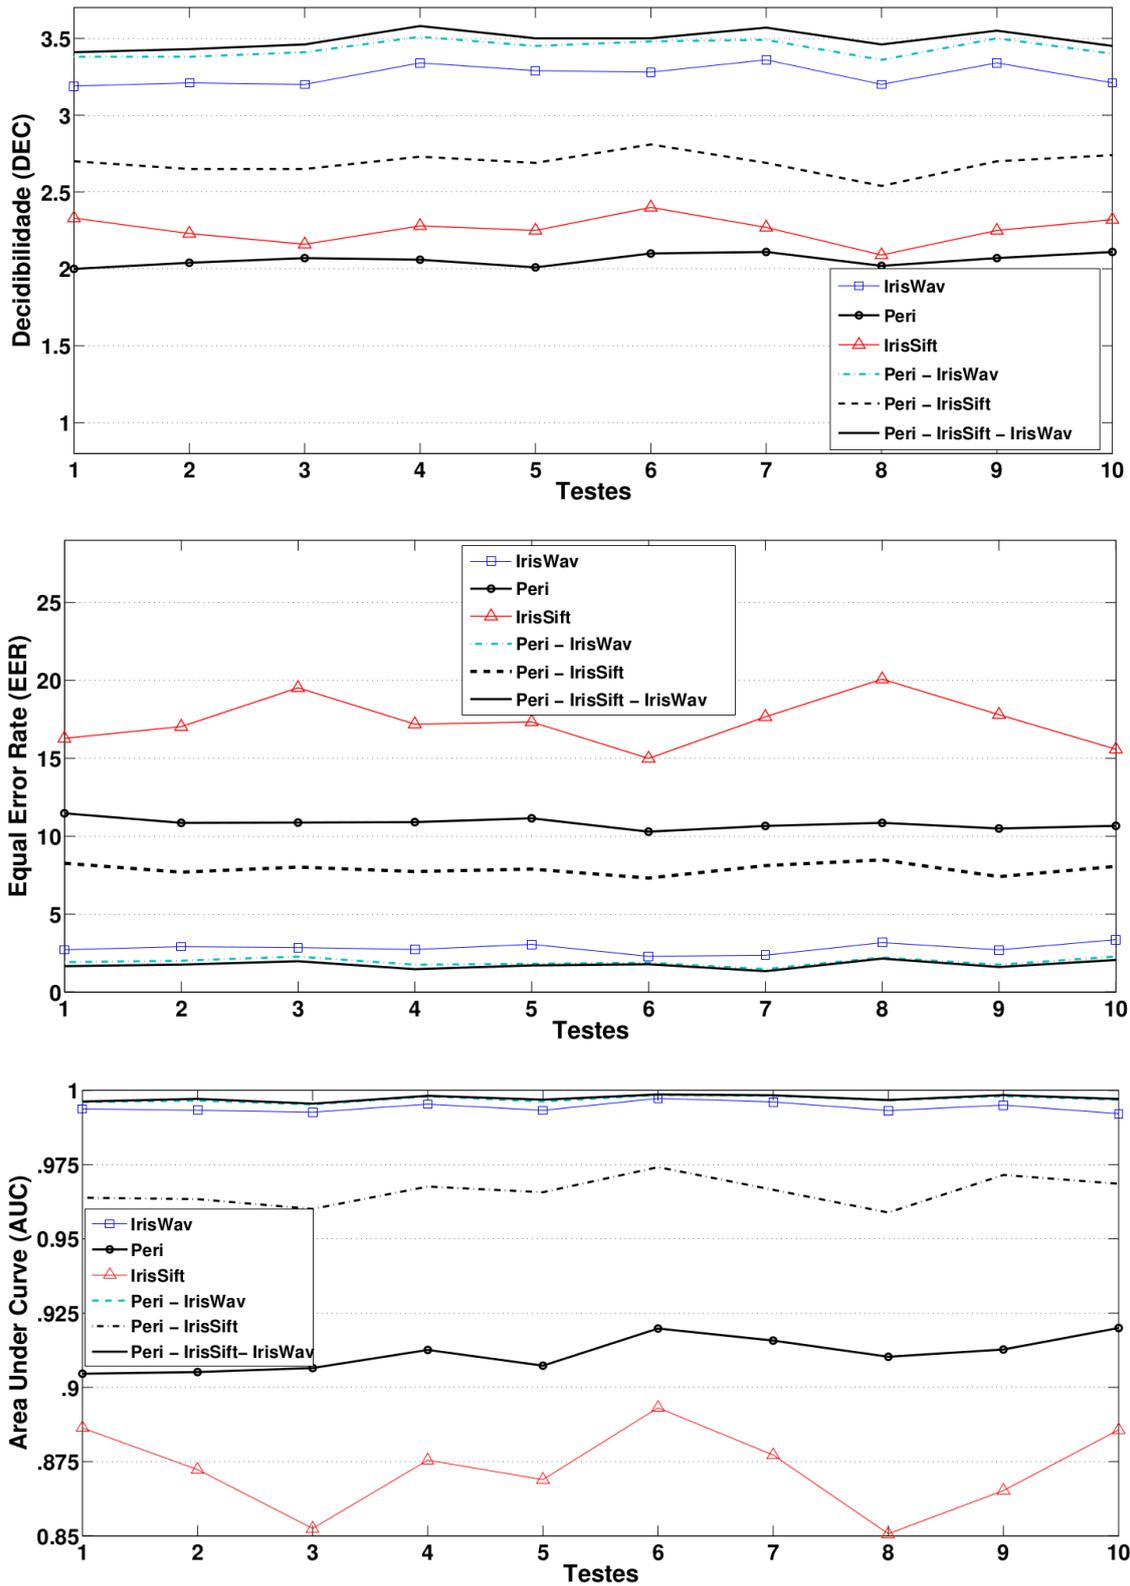


Figura 5.13: Testes de desempenho utilizando a versão Thousand.

A fusão apresentada no capítulo anterior mostrou um aumento na decidibilidade de 17% com respeito ao melhor método individual, a fusão **Peri-IrisSift-IrisWav** teve uma melhoria de 14% com um desvio padrão de 2,5 na versão *Lamp*. A versão

Thousand teve um aumento de 9% com um desvio padrão de 0,7 com respeito ao método individual com melhor desempenho. Mas a redução do tempo de processamento conseguido foi de 50%, o que permitiria fazer uso do método em situações onde é possível sacrificar um pouco a segurança, com o objetivo de conseguir uma maior fluidez dos usuários.

Capítulo 6

Conclusões e trabalhos futuros

6.1 Conclusões

Nesta tese de doutorado, após um resumo do que foi apresentado na literatura, foi descrita a metodologia usada para as segmentações da pupila e da íris, e para a localização das pálpebras. Posteriormente, foi apresentada a técnica proposta para a normalização da íris. Em seguida foram detalhados os métodos e as fusões propostas para o reconhecimento biométrico de pessoas. Finalmente foram mostrados os resultados dos testes de desempenho realizados com os métodos apresentados.

A segmentação da íris proposta foi avaliada em dois bancos de imagens com diferentes características, empregando quase 10.000 imagens de cada banco. O resultado da avaliação mostrou um desempenho aceitável na segmentação, mesmo em imagens contendo óculos e reflexos.

Em referência ao método de normalização proposto, ele mostrou uma diminuição do custo computacional que pode chegar a 98%, com uma pequena perda no desempenho em termos de exatidão do reconhecimento em comparação ao método de Daugman. A diminuição no tempo de processamento pode ser aproveitada em sistemas multiamostras para permitir processar uma maior quantidade de imagens.

Diferentes métodos de reconhecimento com sistemas resultantes das fusões dos mesmos foram apresentados e avaliados. A avaliação apresentou um incremento na performance da identificação após a fusão dos métodos. O sistema biométrico multimodal para um sistema de reconhecimento sem cooperação dos usuários foi premiado com o terceiro lugar no NICE.II (*Noisy Iris Challenge Evaluation - Part 2*), uma competição internacional envolvendo quase setenta participantes de diferentes países.

Com respeito aos métodos perioculares, principalmente o método SIFT no teste com as imagens capturadas sem cooperação, tiveram uma menor performance individualmente por causa da mudança na perspectiva das imagens capturadas, e porque

algumas imagens quase não apresentavam região periocular. Entretanto, ao serem combinados junto com os métodos que utilizam características da íris, a fusão resultante mostrou uma melhor performance em relação ao método melhor avaliado individualmente.

Nos testes individuais dos métodos que utilizam informação da íris, o método que usa a wavelet de uma dimensão mostrou superioridade na performance do reconhecimento, e menor complexidade computacional ao normalizar a íris numa matriz de 200×16 , ao invés de usar uma matriz de 450×64 requerida pelo método de mapas de comparações.

Foram testados diferentes sistemas biométricos multimodais, e concluiu-se que o método que utiliza a wavelet 1-D na íris e o método que emprega o SIFT na região periocular, são os métodos que mais aportam para melhorar o desempenho do reconhecimento, com respeito aos métodos empregados nesta pesquisa.

6.2 Trabalhos futuros

O método proposto pode se tornar menos invasivo, permitindo com que as imagens sejam capturadas a uma distância maior. Os detalhes da íris e da região periocular podem ser realçados usando técnicas de super-resolução. Entretanto, como essas técnicas precisam de várias imagens consecutivas, será necessário implementar um sistema de captura usando vídeo.

Neste trabalho, a região periocular de cada olho foi tratada separadamente. O processamento da região periocular dos dois olhos em conjunto pode ajudar a melhorar o desempenho da identificação.

A normalização proposta funciona quando a pupila é tratada como um círculo, mas existem algumas técnicas que usam o contorno da pupila, que pode não ser circular. Modificar o método para que funcione com qualquer técnica seria uma contribuição interessante.

A localização dos dois pontos de um casamento realizado pelo método SIFT poderia servir para extrair outras características, como por exemplo a textura em torno desses pontos.

Referências Bibliográficas

- [1] CLARKE, R. “Human identification in information systems: management challenges and public policy issues”, *Information Technology and People*, v. 7, n. 4, pp. 6 – 37, 1994.
- [2] SCIENCE, N., (NTSC), T. C. “Iris Recognition”. <http://www.biometrics.gov/>, Aug 2007.
- [3] DAUGMAN, J. G. “How iris recognition works”, *Circuits and Systems for Video Technology, IEEE Transactions on*, v. 14, n. 1, pp. 21–30, Jan 2004.
- [4] WILDES, R. “Iris recognition: an emerging biometric technology”, *Proceedings of the IEEE*, v. 85, n. 9, pp. 1348 –1363, sep. 1997.
- [5] BOLES, W. “A security system based on human iris identification using wavelet transform”. In: *KES '97: Proceedings of the First International Conference on Knowledge-Based Intelligent Electronic Systems*, v. 2, pp. 533–541, May 1997.
- [6] BOLES, W., BOASHASH, B. “A human identification technique using images of the iris and wavelet transform”, *Signal Processing, IEEE Transactions on*, v. 46, n. 4, pp. 1185–1188, Apr 1998.
- [7] MA, L., TAN, T., WANG, Y., et al. “Personal identification based on iris texture analysis”, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 25, n. 12, pp. 1519–1533, Dec 2003.
- [8] MA, L., TAN, T., WANG, Y., et al. “Efficient iris recognition by characterizing key local variations”, *Image Processing, IEEE Transactions on*, v. 13, n. 6, pp. 739–750, June 2004.
- [9] SANCHEZ, C., SANCHEZ-REILO, R. “Multiscale Analysis for Iris Biometrics”. In: *36th Annual 2002 International Carnahan Conference on Security Technology*, 2001.

- [10] SANCHEZ-AVILA, C., SANCHEZ-REILLO, R., DE MARTIN-ROCHE, D. “Iris-based biometric recognition using dyadic wavelet transform”, *Aerospace and Electronic Systems Magazine, IEEE*, v. 17, n. 10, pp. 3–6, Oct 2002.
- [11] MONRO, D., RAKSHIT, S., ZHANG, D. “DCT-Based Iris Recognition”, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 29, n. 4, pp. 586–595, April 2007.
- [12] KAUSHIK, R., PRABIR, B. “Optimal features subset selection and classification for iris recognition”, *J. Image Video Process.*, v. 2008, n. 3, pp. 1–20, 2008.
- [13] POURSAHERI, A., ARAABI, B. N. “Iris recognition for partially occluded images: methodology and sensitivity analysis”, *EURASIP J. Appl. Signal Process.*, v. 2007, n. 1, pp. 20–20, 2007.
- [14] NOH, S., PAE, K., LEE, C., et al. “Multiresolution Independent Component Analysis for Iris Identification”. In: *In Proc. of the International Conference on Circuits/Systems Computers and Communications*, 2012.
- [15] LI, Y., DAVID, Z., KUANQUAN, W. “The relative distance of key point based iris recognition”, *Pattern Recognition*, v. 40, n. 2, pp. 423–430, 2007.
- [16] RAJ, N., MICHAEL, T., SAMIR, N. *Biometrics: Identity Verification In a Networked World*. Hoboken, NJ, John Wiley & Sons, 2002.
- [17] ERICKSON, M. *Eye Anatomy*. Relatório técnico, St. Luke’s Cataract & Laser Institute, 1996.
- [18] KRONFELD, P. *The Gross Anatomy and Embryology of the Eye*. Chicago, Ed. London: Academic, 1962.
- [19] BORGES, H., BOURS, P., WOLTHUSEN, S. “Visible-Spectrum Biometric Retina Recognition”. In: *Intelligent Information Hiding and Multimedia Signal Processing, 2008. IHHMSP ’08 International Conference on*, pp. 1056–1062, Aug 2008.
- [20] PROENÇA, H., ALEXANDRE, L. “A Method for the Identification of Noisy Regions in Normalized Iris Images”, *Pattern Recognition, 2006. ICPR 2006. 18th International Conference on*, v. 4, pp. 405–408, 2006.
- [21] MITCHELL, R. L. “Forget Fingerprints: Your Iris Is Your New Identity”, *COMPUTERWORLD*, Set 2013.

- [22] DAUGMAN, J. “High confidence recognition of persons by iris patterns”. In: *Security Technology, 2001 IEEE 35th International Carnahan Conference on*, pp. 254–263, Oct 2001.
- [23] HAN, M., SUN, W., LI, M. “Iris Recognition Based on a Novel Normalization Method and Contourlet Transform”. In: *Image and Signal Processing, 2009. CISP '09. 2nd International Congress on*, pp. 1–3, oct. 2009.
- [24] YUAN, X., SHI, P. “A Non-linear Normalization Model for Iris Recognition”. In: Li, S., Sun, Z., Tan, T., et al. (Eds.), *Advances in Biometric Person Authentication*, v. 3781, *Lecture Notes in Computer Science*, Springer Berlin / Heidelberg, pp. 135–141, 2005.
- [25] WYATT, H. J. “A minimum-wear-and-tear meshwork for the iris”, *Vision Research*, v. 40, n. 16, pp. 2167 – 2176, 2000.
- [26] KANT, C., NATH, R. “International Journals of Biometric and Bioinformatics”, *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, v. 3, n. 1, pp. 1–9, 2009.
- [27] JAIN, A., ROSS, A. “Iris Recognition Based on Local Feature Point Matching”. In: *Multibiometric systems*, v. 47, pp. 34–40, 2004.
- [28] PHILLIPS, P., GROTH, P., ROSS, M., et al. *FRVT 2002: overview and summary*. Relatório técnico, Mar 2003.
- [29] WOODARD, D., PUNDLIK, S., LYLE, J., et al. “Periocular region appearance cues for biometric identification”. In: *Computer Vision and Pattern Recognition Workshops (CVPRW), 2010 IEEE Computer Society Conference on*, pp. 162–169, 2010.
- [30] PARK, U., ROSS, A., JAIN, A. “Periocular biometrics in the visible spectrum: A feasibility study”. In: *BTAS '09: Proceedings of the IEEE 3rd International Conference on Biometrics: Theory, Applications, and Systems*, pp. 1–6, Sept 2009.
- [31] PARK, U., ROSS, A., JAIN, A. “Periocular biometrics in the visible spectrum: A feasibility study”. In: *Biometrics: Theory, Applications, and Systems, 2009. BTAS '09. IEEE 3rd International Conference on*, pp. 1–6, 2009.
- [32] JUEFEI-XU, F., LUU, K., et al. “Investigating age invariant face recognition based on periocular biometrics”. In: *Biometrics (IJCB), 2011 International Joint Conference on*, pp. 1–7, 2011.

- [33] LYLE, J., MILLER, P., PUNDLIK, S., et al. “Soft biometric classification using periocular region features”. In: *Biometrics: Theory Applications and Systems (BTAS), 2010 Fourth IEEE International Conference on*, pp. 1–7, 2010.
- [34] BOWYER, K. “The results of the NICE.II Iris biometrics competition”, *Pattern Recognition Letters*, v. 33, n. 8, pp. 965 – 969, 2012.
- [35] PROENÇA, H., FILIPE, S., SANTOS, R., et al. “The UBIRIS.v2: A Database of Visible Wavelength Iris Images Captured On-the-Move and At-a-Distance”, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 32, n. 8, pp. 1529 –1535, Aug 2010.
- [36] LOWE, D. “Distinctive Image Features from Scale-Invariant Keypoints”, *International Journal of Computer Vision*, v. 60, pp. 91–110, 2004.
- [37] HEIKKI, K., JUSSI, P., ARTO, K. “Image Analysis with Local Binary Patterns”. In: *Image Analysis*, v. 3540, *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, pp. 115–118, 2005.
- [38] SANTOS, G., PROENÇA, H. “Iris Recognition: Analyzing the Distribution of Iriscodes Concordant Bits”. In: *Image and Signal Processing (CISP), 2010 3rd International Congress on*, v. 4, pp. 1873–1877, Oct 2010.
- [39] HOYLE, E. *Reconhecimento de íris usando transformada wavelet e zero-crossing*. Tese de Mestrado, Univerisdade Federal de Rio de Janeiro, 2009.
- [40] HOYLE, E., LEITE, P., FEITOSA, R. “An Extension To Boles Method To Cope With Occlusion”. In: *In Proc. III Workshop de Visão Computacional*, Oct 2007.
- [41] HOYLE, E., FEITOSA, R., PETRAGLIA, A. “Iris Recognition Using One-Dimensional Signal Analysis”. In: *Proceedins of the 8th International Seminar on Electrical Metrology*, Jun 2009.
- [42] HOYLE, E., FEITOSA, R., PETRAGLIA, A. “Robust Iris Segmentation for Biometric Recognition”. In: *VIII Semetro Book*, cap. 8, pp. 141–161, Campina Frande, EDUFCG: Editora da Universidade Federal de Campina Grande, 2010.
- [43] HOYLE, E., SANTOS, G. “A fusion approach to unconstrained iris recognition”, *Pattern Recognition Letters*, v. 33, n. 8, pp. 984 – 990, 2012.

- [44] HOYLE, E., PETRAGLIA, A. “A novel approach to iris normalization using non-concentric circles”. In: *A International Workshop on "Intelligent Pattern Recognition and Applications" WIPRA '2013*, pp. 84–90, 2013.
- [45] TAN, T., ZHANG, X., SUN, Z., et al. “Noisy iris image matching by using multiple cues”, *Pattern Recognition Letters*, v. 33, n. 8, pp. 970 – 977, 2012.
- [46] “CASIA Iris Database, Center for Biometrics and Security Research”. <http://www.cbsr.ia.ac.cn/english/IrisDatabase.asp>, Aug 2013.
- [47] BALLARD, D. “Generalizing the Hough transform to detect arbitrary shapes”, *Pattern Recognition*, v. 13, n. 2, pp. 111–122, 1981.
- [48] CANNY, J. “A Computational Approach to Edge Detection”, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. PAMI-8, n. 6, pp. 679–698, November 1986.
- [49] DAUGMAN, J., WILLIAMS, G. “A proposed standard for biometric decidability”, in *Proceedings of the CardTech/SecureTech Conference*, pp. 223–234, 1996.
- [50] DAUGMAN, J. *Results from 200 billion iris cross-comparisons*. Relatório técnico, University of Cambridge, 2005.
- [51] JOSHI, N., LAMBA, R., SHAH, D., et al. “Implementation of various approaches for iris image normalization”. In: *Engineering (NUiCONE), 2011 Nirma University International Conference on*, pp. 1–5, Dec 2011.
- [52] SAVVIDES, M., JR., K. R., WOODARD, D. L., et al. “Unconstrained Biometric Identification: Emerging Technologies”, *Computer*, v. 43, pp. 56–62, 2010.
- [53] MILLER, P. E., RAWLS, A. W., PUNDLIK, S. J., et al. “Personal identification using periocular skin texture”. In: *SAC '10: Proceedings of the 2010 ACM Symposium on Applied Computing*, pp. 1496–1500, New York, NY, USA, 2010. ACM.
- [54] SUGIYAMA, M. “Local Fisher discriminant analysis for supervised dimensionality reduction”. In: *ICML '06: Proceedings of the 23rd international conference on Machine learning*, pp. 905–912, New York, NY, USA, 2006. ACM Press.
- [55] HOSMER, D., STANLEY, L. *Applied logistic regression Wiley Series in probability and statistics*. New York, Wiley-Interscience Publication, Sep 2000.

- [56] DAUBECHIES, I. *Ten Lectures on Wavelets*. Philadelphia, PA, SIAM, 1992.
- [57] UZAIR, M., MAHMOOD, A., MIAN, A., et al. “Periocular biometric recognition using image sets”. In: *Applications of Computer Vision (WACV), 2013 IEEE Workshop on*, pp. 246–251, 2013.
- [58] FRIEDMAN, J. H., BENTLEY, J. L., FINKEL, R. A. “An Algorithm for Finding Best Matches in Logarithmic Expected Time”, *ACM Trans. Math. Softw.*, v. 3, n. 3, pp. 209 – 226, 1977.
- [59] BEIS, J., LOWE, D. “Shape indexing using approximate nearest-neighbour search in high-dimensional spaces”. In: *Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on*, pp. 1000–1006, 1997.
- [60] BHARADWAJ, S., BHATT, H., VATSA, M., et al. “Periocular biometrics: When iris recognition fails”. In: *Biometrics: Theory Applications and Systems (BTAS), 2010 Fourth IEEE International Conference on*, pp. 1–6, Sep 2010.
- [61] VEDALDI, A., FULKERSON, B. “VLFeat: An Open and Portable Library of Computer Vision Algorithms”. <http://www.vlfeat.org/>, 2008.
- [62] AGRETI, A. *Categorical Data Analysis (Wiley Series in Probability and Statistics)*. Hoboken, NJ, Wiley Interscience, July 2002.
- [63] CANTOR, A. B. M. “Understanding logistic regression”, *Evidence-based Oncology*, v. 3, n. 2, pp. 52–53, 2002.
- [64] MONWAR, M., GAVRILOVA, M. “FES: A System for Combining Face, Ear and Signature Biometrics Using Rank Level Fusion”. In: *Information Technology: New Generations, 2008. ITNG 2008. Fifth International Conference on*, pp. 922–927, 2008.
- [65] MONWAR, M., GAVRILOVA, M. “Multimodal Biometric System Using Rank-Level Fusion Approach”, *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, v. 39, n. 4, pp. 867–878, 2009.
- [66] RAPOSO, R., HOYLE, E., PEIXINHO, A., et al. “UBEAR: A dataset of ear images captured on-the-move in uncontrolled conditions”. In: *Computational Intelligence in Biometrics and Identity Management (CIBIM), 2011 IEEE Workshop on*, pp. 84–90, 2011.

- [67] ALONSO-FERNANDEZ, F., TOME-GONZALEZ, P., RUIZ-ALBACETE, V., et al. “Iris recognition based on SIFT features”. In: *Biometrics, Identity and Security (BIDS), 2009 International Conference on*, pp. 1–8, 2009.
- [68] ZHU, R., YANG, J., WU, R. “Iris Recognition Based on Local Feature Point Matching”. In: *Communications and Information Technologies 2006 IS-CIT '06. International Symposium on*, pp. 451–454, 2006.
- [69] MESECAN, I., ELEYAN, A., KARLIK, B. “Sift-based iris recognition using sub-segments”. In: *Technological Advances in Electrical, Electronics and Computer Engineering (TAECE), 2013 International Conference on*, pp. 350–353, 2013.