



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Métricas de Qualidade Aplicadas em Sistemas de Reconhecimento de Íris

Victor Araújo Vieira

Monografia apresentada como requisito parcial
para conclusão do Curso de Engenharia da Computação

Orientador

Prof. Dr. Bruno Luigi Macchiavello Espinoza

Brasília
2019

Dedicatória

Dedico este projeto aos meus pais, Francisco e Maria Stela, pelo amor, criação, suporte e oportunidades que me deram de forma a chegar até aqui e por me tornarem na pessoa que sou hoje. Dedico aos meus tios, Marcelo e Ângela, e primos, Gabriel, André e Bruno, por todo o apoio e carinho que me deram e suporte ao longo da vida. Dedico também à minha namorada Camila, por toda compreensão, amor, carinho e apoio ao longo da caminhada na UnB.

Agradecimentos

Gostaria de agradecer ao meu orientador Bruno Macchiavello, por todo suporte e aconselhamento ao longo deste projeto e do *PIBIC* que me orientou. Agradeço a todos os professores da universidade que me garantiram uma educação boa e de qualidade apesar de todas dificuldades. Para toda a minha família, agradeço por todo apoio incondicional, em especial às minhas avós Zilah e Joana e avô Wildson. Agradeço a todos os amigos que ganhei na UnB, todas as madrugadas de trabalho e comendo pizza na UnB foram melhores por conta de vocês.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), por meio do Acesso ao Portal de Periódicos.

Resumo

A qualidade de imagens de íris em sistemas de reconhecimento de íris influencia diretamente na etapa de segmentação, assim como a qualidade da segmentação afeta a extração dos atributos que identificam unicamente uma pessoa. Este projeto propõe, então, o estudo da aplicação de duas métricas de qualidade, uma para avaliar a qualidade de imagens de íris de comprimento de *luz visível* e outra para avaliar a qualidade da etapa de segmentação de íris, em sistemas de reconhecimento de íris. Uma arquitetura de sistemas de reconhecimento de íris é proposta com as métricas *Índice de Sinal-Magnitude Diferencial (DSMI)* e *Avaliação da Correlação de Atributos (FCE)*. Os experimentos são realizados utilizando um sistema de reconhecimento de íris *open source* e quatro bancos de imagens de íris de *luz visível*. A arquitetura proposta melhorou consideravelmente o desempenho de sistemas de reconhecimento de íris nos dois bancos com imagens mais comportadas e melhorou pouco ou piorou o desempenho dos outros dois bancos. No entanto, os dois resultados adversos estão mais relacionados com o banco de imagens do que com a arquitetura proposta, de forma que pode-se afirmar que a arquitetura tem o potencial de ser utilizada em sistemas de reconhecimento de íris.

Palavras-chave: Reconhecimento de íris, Biometria, Métricas de Qualidade

Abstract

Iris images quality in iris recognition systems are strongly related to the segmentation step success, as the segmentation quality in the iris feature extraction step that identifies uniquely a person. This project consists of a study on the application of two quality metrics, one for measuring the quality of iris images in the visible light wavelength and the other for measuring the iris segmentation step quality in iris recognition systems. An iris recognition framework is proposed with the quality metrics Differential Sign-Magnitude Statistics Index (DSMI) and Feature Correlation Evaluation (FCE). The experiments were performed using an open source iris recognition system and four visible light wavelength iris image datasets. The proposed framework improved considerably the performance of iris recognition systems in two of the datasets with images captured in a more controlled environment and improved a little or got worse the performance in the other two datasets. However, the two unfavorable results are more related to the datasets than the proposed framework, so it can be affirmed that the framework has the potential for being applied in iris recognition systems.

Keywords: Iris recognition, Biometrics, Quality Metrics

Sumário

1	Introdução	1
1.1	Objetivo Geral	2
1.2	Objetivos Específicos	2
1.3	Organização	3
2	Fundamentação Teórica	4
2.1	Biometria	4
2.1.1	Características biométricas	4
2.1.2	Qualidade das características biométricas	5
2.2	Sistemas biométricos	6
2.2.1	Módulo de Coleta	7
2.2.2	Módulo de Transmissão	7
2.2.3	Módulo de Processamento	8
2.2.4	Módulo de Armazenamento	9
2.2.5	Módulo de Decisão	9
2.3	Processamento de Imagens no Domínio Espacial	9
2.3.1	<i>Padrões Binários Locais (LBP)</i>	10
2.3.2	<i>Filtro Variância Local</i>	11
2.3.3	<i>Método Otsu</i>	12
2.4	Processamento Morfológico de Imagens	13
2.4.1	Dilatação	14
2.4.2	Erosão	14
2.5	Filtragem de Imagens	15
2.5.1	<i>Filtro Log-Gabor</i>	16
2.6	Sistemas Biométricos de Íris	17
2.6.1	Olho humano	17
2.6.2	<i>Imagens Luz Visível (LV) vs Perto do Infravermelho (NIR)</i>	18
2.6.3	Reconhecimento de íris	19

3	Revisão Bibliográfica	23
3.1	<i>Índice de Sinal-Magnitude Diferencial (DSMI)</i>	25
3.2	<i>Avaliação da Correlação de Atributos (FCE)</i>	27
4	Metodologia	30
4.1	Arquitetura proposta	30
4.1.1	DSMI	31
4.1.2	Segmentação	33
4.1.3	FCE	35
4.1.4	Codificação	36
4.1.5	Correspondência	37
5	Resultados	39
5.1	Bancos de imagens	39
5.1.1	<i>MICHE</i>	40
5.1.2	<i>UBIRISv1</i>	41
5.1.3	<i>UBIRISv2</i>	42
5.1.4	<i>Warsaw</i>	43
5.1.5	Limiares T_{DSMI} e T_{FCE}	44
5.1.6	Ruídos	45
5.2	Segmentação	47
5.3	Experimentos de Reconhecimento de Íris	49
5.3.1	<i>Área Sobre a Curva (AUC) e Característica do Operador do Receptor (ROC)</i>	50
5.3.2	<i>Taxa de Erro Igual (EER)</i>	52
5.3.3	<i>Índice de Daugman (d')</i>	53
6	Conclusão	55
	Referências	57

Lista de Figuras

1.1	Ruídos comuns em imagens de íris.	2
2.1	Arquitetura de um sistema biométrico genérico. Linhas contínuas indicam módulos obrigatórios e linhas tracejadas indicam módulos opcionais.	7
2.2	Sensores biométricos de impressão digital e íris.	7
2.3	Resultados da segmentação de uma íris e impressão digital.	8
2.4	Imagem de entrada.	11
2.5	Resultados da filtragem da Figura 2.4 usando os filtros <i>Desvio Padrão Local</i> e <i>Variância Local</i>	11
2.6	Processo de binarização de imagens utilizando o método <i>Otsu</i>	13
2.7	Exemplo de elemento estruturante. O elemento central sublinhado é o <i>ponto âncora</i>	13
2.8	Resultado da etapa de dilatação. A matriz 3x3 centralizada corresponde ao elemento estruturante e o elemento sublinhado ao <i>ponto âncora</i> substituído pelo máximo valor da região sobreposta.	14
2.9	Imagem de entrada e saída da operação de dilatação.	15
2.10	Imagem de entrada e saída da operação de erosão.	15
2.11	Função de ativação do filtro <i>Log-Gabor</i> na escala linear.	16
2.12	Anatomia de um olho humano.	18
2.13	Diferença das íris do olho humano (Fonte: [1]).	18
2.14	Espectro de ondas eletromagnéticas.	18
2.15	Imagens de íris <i>LV</i> (Fonte: [1]).	19
2.16	Imagem de íris <i>NIR</i>	19
2.17	Procedimento do <i>Modelo Rubber Sheet</i>	20
2.18	Processo de normalização de uma imagem de íris segmentada.	21
2.19	Codificação pelos quadrantes do plano <i>complexo</i> das <i>Wavelets 2D de Gabor</i>	21
2.20	Imagem segmentada e seu <i>IrisCode</i> gerado.	22

4.1	Diagrama da arquitetura de sistema de reconhecimento de íris com as métricas de qualidade $DSMI$ e FCE proposta. T_{DSMI} é o limiar definido para a métrica $DSMI$, T_{FCE} o limiar da métrica FCE e T o limiar para aceitar ou rejeitar um indivíduo que está sendo autenticado a partir da <i>Distância Hamming</i> (HD) calculada entre seus modelos.	30
4.2	Representação do módulo da métrica de qualidade $DSMI$ no diagrama da arquitetura proposta. A entrada é uma imagem de íris LV e saída é a qualidade da imagem Q_{DSMI} , sendo um valor entre 0 e 1. Enfim, o módulo deve decidir se a imagem é ou não boa o suficiente com base no limiar T_{DSMI} . 32	32
4.3	Módulo que segmenta e normaliza a imagem de íris. As etapas de segmentação e normalização são divididas em dois blocos separados, de forma que qualquer algoritmo de segmentação ou normalização pudesse ser usado. Sua entrada consiste na imagem de íris LV e suas saídas são as posições centrais e raio da íris e pupila, máscaras binárias da íris e da íris normalizada, e a íris normalizada.	33
4.4	Imagem de íris LV	33
4.5	Íris da Figura 4.4 segmentada. Os valores encontrados para (X_p, Y_p, R_p) e (X_i, Y_i, R_i) foram: (419, 274, 52) e (414, 276, 183), respectivamente. . . .	34
4.6	Íris da Figura 4.4 normalizada.	35
4.7	Módulo da métrica de qualidade FCE que calcula a qualidade da segmentação da íris. Recebe como entrada a íris e a máscara normalizadas e os raios da pupila e íris. A saída consiste na qualidade da segmentação Q_{FCE} , sendo um valor entre 0 e 1. O módulo deve então decidir se a segmentação da íris foi boa o suficiente para ser codificada, de acordo com o limiar T_{FCE} . 35	35
4.8	Módulo que codifica a íris segmentada. As etapas de extração dos atributos e codificação são divididas em dois submódulos. Sua entrada consiste na íris normalizada em coordenadas polares, resultado do módulo de segmentação, e sua saída é o código da íris (<i>IrisCode</i>).	37
4.9	<i>IrisCode</i> da Figura 4.4 gerado pelo <i>OSIRISv4.1</i> . Pode-se notar que são 6 códigos de íris combinados em um só, para cada um dos filtros <i>Gabor</i> aplicados.	37
4.10	Módulo que calcula a <i>Distância Hamming</i> (HD) entre dois modelos e decide se correspondem ou não a mesma pessoa. O módulo recebe como entrada dois <i>IrisCodes</i> e duas máscaras binárias normalizadas correspondentes, A e B. Então calcula a HD seguindo a Equação 2.17, e a compara com o limiar T definido para o sistema e, caso seja menor, aceita a autenticação e rejeita caso contrário.	38

4.11	Processos realizados para calcular a <i>Distância Hamming (HD)</i> entre os modelos obtidos dos processos de segmentação e codificação de um indivíduo. Operação <i>booleana AND</i> é feita entre duas máscaras binárias normalizadas em posições definidas nos pontos de aplicação. A operação <i>XOR</i> é então aplicada nos pontos de aplicação que não são ruídos, obtidos no resultado da operação <i>AND</i>	38
5.1	Imagens sem a presença de ruídos do <i>MICHE</i>	41
5.2	Imagens com distorções do <i>MICHE</i>	41
5.3	Imagens da primeira sessão do <i>UBIRISv1</i>	42
5.4	Imagens da segunda sessão do <i>UBIRISv1</i>	42
5.5	Imagens do banco de imagens <i>UBIRISv2</i> capturadas a 5 e 4 metros da câmera.	43
5.6	As imagens (a)-(c) ilustram olhos esquerdos e (d)-(f) olhos direitos da primeira sessão do <i>Warsaw</i> de pessoas diferentes.	44
5.7	Imagem original e imagens resultantes para cada ruído.	46
5.8	Resultados das segmentações de íris dos bancos de imagens <i>MICHE</i> , <i>UBIRISv1</i> e <i>Warsaw</i>	48
5.9	Resultados da segmentação do banco de imagens <i>UBIRISv2</i>	48
5.10	Curvas <i>ROC</i> e <i>AUC</i> calculados para as imagens do experimento de cada banco de imagens. Nos gráficos, <i>Sem</i> são as <i>AUC</i> que foram calculadas sem nenhuma métrica de qualidade e <i>Ambas</i> significa <i>AUC</i> calculadas com as duas métricas de qualidade.	51

Lista de Tabelas

5.1	Valores dos limiares T_{DSMI} e T_{FCE} calculados para todos os bancos de imagens.	45
5.2	Ruídos gerados e os parâmetros utilizados	46
5.3	Parâmetros de diâmetros da pupila e íris usados no sistema <i>OSIRISv4.1</i> para os bancos de imagens <i>MICHE</i> , <i>UBIRISv1</i> e <i>Warsaw</i>	47
5.4	Parâmetros de diâmetros da pupila e íris usados no sistema <i>OSIRISv4.1</i> para o banco de imagens <i>UBIRISv2</i>	47
5.5	Valores calculados para <i>EER</i> dos bancos de imagens.	52
5.6	Valores calculados para d' nos experimentos.	54

Lista de Abreviaturas e Siglas

AUC Área Sobre a Curva.

BIQI Índices de Qualidade de Imagens Cegos.

CLBP Padrões Binários Locais Completos.

d' Índice de Daugman.

DM Usando as duas métricas.

DSMI Índice de Sinal-Magnitude Diferencial.

EER Taxa de Erro Igual.

FCE Avaliação da Correlação de Atributos.

FNR Taxa de Falso Negativo.

FPR Taxa de Falso Positivo.

FR Referência Completa.

HD Distância Hamming.

LBP Padrões Binários Locais.

LV Luz Visível.

MVG Modelos Multivariados Gaussianos.

NIR Perto do Infravermelho.

NR Sem Referência.

NR-IQA Avaliação de Qualidade de Imagens Sem Referência.

OID Operador Integro-Diferencial.

ROC Característica do Operador do Receptor.

ROI Regiões de Interesse.

RR Referência Reduzida.

SFIM Métrica Seletiva de Informação dos Atributos.

SIFT Transformada de Atributos Invariantes a Escala.

SM Sem nenhuma métrica.

SSEQ Qualidade baseada em Entropia Espacial-Espectral.

TNR Taxa de Verdadeiro Negativo.

TPR Taxa de Verdadeiro Positivo.

Warsaw Warsaw-BioBase-Smartphone-Iris-v1.0.

WGN Ruído Branco Gaussiano.

Capítulo 1

Introdução

Biometria é uma característica física ou comportamental que identificam uma pessoa unicamente [2]. Desde suas descobertas e com o avanço tecnológico das últimas décadas, especialmente com os *smartphones*, biometria têm ganho grande destaque na comunidade científica. Características biométricas como impressão digital, rosto e íris têm sido usadas em diversas aplicações, como controlar o acesso de pessoas em locais, controlar o acesso de pessoas em contas bancárias, confirmar pagamento e muitas outras [2, 3].

A íris é uma das características biométricas com maior confiabilidade, porque possui traços imutáveis ao longo da vida e diversos sistemas biométricos têm sido implementados as usando [2, 4, 5, 6]. No entanto, praticamente todos os sistemas usados comercialmente utilizam imagens com comprimento de onda *Perto do Infravermelho (NIR)*, que são adquiridas por meio de câmeras especiais, e apesar de já ser utilizada por alguns *smartphones* sofisticados, seus preços altos impossibilitam o uso de forma mais generalizada. Imagens de comprimento de *Luz Visível (LV)*, ou imagens tiradas por câmeras normais, como as de *smartphones*, também são utilizadas, mas não apresentam as mesmas taxas de eficiência das imagens *NIR* [1, 7, 8, 9]. Um dos fatores responsáveis pela menor taxa de acurácia pode ser explicado pela falta de controle na qualidade de imagens tiradas por câmeras normais, já que geralmente são tiradas pelas próprias pessoas e muitas vezes sobre condições desfavoráveis e porque imagens *LV* possuem algumas deficiências para capturar padrões da íris, especialmente de íris com pigmentação escuras [10].

Sistemas de reconhecimento de íris são implementados seguindo os três passos: segmentar e normalizar a íris; extrair atributos da íris segmentada e codificá-los, de forma a gerar o código de íris (*IrisCode*); e comparar códigos gerados de forma a verificar se são ou não da mesma pessoa [2]. A etapa mais importante de sistemas de reconhecimento de íris é a segmentação, porque é nela que a íris é separada do restante da imagem de entrada e é utilizada para ser codificada [4]. Muitas tentativas foram feitas para auxiliar os algoritmos de segmentação e, conseqüentemente, melhorar o desempenho de sistemas

de reconhecimento de íris, como o cálculo da qualidade das imagens de íris de entrada do sistema [4, 11, 12, 13, 14, 15, 16, 17] e o cálculo da qualidade da etapa de segmentação [7, 18, 19, 20, 21], onde resultados que melhoraram o desempenho de sistemas de reconhecimento de íris foram encontrados para as duas abordagens. A métrica que apresentou o maior potencial e os melhores resultados para calcular a qualidade de imagens de íris *LV* foi o *Índice de Sinal-Magnitude Diferencial (DSMI)* [12], por considerar os ruídos mais comuns em imagens de íris, como os ilustrados na Figura 1.1. Já para a qualidade da etapa de segmentação, a melhor métrica foi o *Avaliação da Correlação de Atributos (FCE)* [18] por levar em conta fatores como a qualidade dos padrões da íris, e fatores como ruídos e dilatação da pupila. No entanto, não foram encontrados projetos que calculam as qualidades da imagem de íris de entrada e da etapa de segmentação na mesma arquitetura do sistema de reconhecimento de íris.




Figura 1.1: Ruídos comuns em imagens de íris.

1.1 Objetivo Geral

Este projeto propõe uma arquitetura de sistema de reconhecimento de íris que utiliza duas métricas de qualidade: uma para avaliar a qualidade de imagens de íris *LV* (*DSMI*) e outra para avaliar a qualidade da etapa de segmentação de sistemas de reconhecimento de íris (*FCE*).

1.2 Objetivos Específicos

1. Implementar as duas métricas de qualidade *DSMI* e *FCE*;
2. Propor uma arquitetura com as duas métricas de qualidade e flexível para usar qualquer sistema de reconhecimento de íris, ou seja, sistemas que implementam

as etapas de segmentação, codificação e correspondência de íris. Neste projeto foi utilizado o sistema *open source OSIRISv4.1* [6];

3. Avaliar como as duas métricas podem influenciar no desempenho de sistemas de reconhecimento de íris, utilizando quatro bancos de imagens com imagens de íris *LV: MICHE* [22], *UBIRISv1* [23], *UBIRISv2* [24] e *Warsaw-BioBase-Smartphone-Iris-v1.0 (Warsaw)* [1].

1.3 Organização

O Capítulo 2 (Fundamentação Teórica) foi reservado para a introdução e explicação dos conceitos necessários para a melhor compreensão do projeto. No Capítulo 3 (Revisão Bibliográfica), é feita uma revisão de estudos e projetos que utilizaram os conceitos de qualidade de imagens, qualidade de imagens de íris e da etapa de segmentação de íris; além de explicar as métricas *DSMI* e *FCE*. O Capítulo 4 (Metodologia) introduz e ilustra a arquitetura de sistema de reconhecimento de íris utilizando as duas métricas de qualidade proposta e explica cada um de seus módulos. O Capítulo 5 (Resultados) introduz os bancos de imagens de íris utilizados e todos os experimentos que foram realizados para avaliar o desempenho da arquitetura proposta. Por fim, o Capítulo 6 (Conclusão) detalha as conclusões encontradas para o projeto proposto e analisa possíveis trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Este capítulo introduz e detalha todos os conceitos teóricos necessários para o entendimento do projeto proposto. Descreve o que é biometria, o que são sistemas biométricos, o que é processamento de imagens no domínio espacial, processamento morfológico de imagens, filtragem em imagens e sistemas de reconhecimento de íris.

2.1 Biometria

A biometria consiste em medidas físicas ou comportamentais que identificam um indivíduo unicamente [3]. Nas últimas décadas, com os avanços das tecnologias, foi possível usar essas medidas biométricas em sistemas de autenticação [2].

As Subseções 2.1.1 e 2.1.2 explicam quais as características biométricas existem e os critérios utilizados para determinar quais são as melhores, respectivamente.

2.1.1 Características biométricas

Características biométricas são as medidas que identificam unicamente uma pessoa. Podem ser divididas em três categorias: físicas, comportamentais e híbridas [3].

Características físicas são aspectos fisiológicos do corpo humano. Como medidas, padrões, cores ou formatos. Algumas das características físicas mais utilizadas são:

- Impressão digital;
- Íris;
- Rosto;
- Formato das mãos;
- Veias das mãos;

- Formato da orelha;
- Retina.

Características comportamentais são aspectos psicológicos, como fatores que levam pessoas a praticarem atividades ou ações que as distinguem unicamente [2]. Alguns dos aspectos comportamentais utilizados para autenticação biométrica são:

- Assinatura;
- Forma de caminhar.

Já características híbridas, são aspectos que envolvem tanto fatores fisiológicos quanto comportamentais, como a voz [2]. Tamanho e formato da boca, garganta, cavidade nasal e outros fatores físicos influenciam diretamente na frequência da voz da pessoa, mas fatores comportamentais como humor, idioma, sotaque e saúde também são essenciais para a diferenciação da voz de indivíduos.

2.1.2 Qualidade das características biométricas

Como explicado na Seção 2.1.1, existem várias características biométricas. Não há consenso para qual a melhor, mas cada uma possui vantagens e desvantagens para a utilização em autenticação biométrica. Cinco critérios são utilizados para avaliar a qualidade das características biométricas [25]:

1. Aceitabilidade: Característica que não sofreria objeções das pessoas para adquiri-la;
2. Robustez: Característica que não sofre mudanças ao longo do tempo, ou seja, imutável;
3. Disponibilidade: Característica que todo ser humano deveria possuir;
4. Distintividade: Característica que possui grande variação em uma população;
5. Acessibilidade: Característica que pode ser facilmente adquirida por meio de sensores.

Além dos cinco fatores descritos acima, a escolha da característica biométrica a ser usada em um sistema depende da aplicação a ser usada, fatores geográficos e das dificuldades para sua implementação, ficando a critério do seu projetista [2].

2.2 Sistemas biométricos

Sistemas biométricos são sistemas computacionais usados para identificar pessoas por meio de algoritmos de reconhecimento biométrico e são projetados para duas hipóteses [2]:

1. Positivas: Amostras submetidas ao sistema pertencem a uma pessoa registrada;
2. Negativas: Amostras submetidas ao sistema pertencem a uma pessoa não registrada.

Sistemas biométricos são implementados para utilizar características biométricas individuais, como íris, impressão digital e reconhecimento facial, ou até mesmo usar várias características ao mesmo tempo e combiná-las [26, 27]. Sistemas biométricos podem ter diferentes objetivos e são usados geralmente para procurar por pessoas conhecidas ou desconhecidas, ou verificar se a pessoa é ou não é quem afirma que é. Podem ser implementados para diferentes ambientes e situações, como em ambientes externos ou internos, ambientes controlados ou não, e com o manuseio ou não de pessoas treinadas para usar o sistema [2]. Sistemas biométricos são utilizados principalmente para controle de acesso de pessoas em locais ou *smartphones*.

Sistemas biométricos tipicamente consistem em dois métodos [2]:

- Verificação: Usuário se identifica, insere sua característica biométrica e então comparações são feitas apenas entre as características registradas do usuário com a inserida, verificando se há ou não correspondência;
- Identificação: Usuário insere sua característica biométrica e é comparada com todas as registradas no sistema, verificando se há ou não correspondência com alguma dependendo da regra adotada pelo sistema.

Os métodos não precisam ser usados individualmente, podendo haver sistemas híbridos, mas em sistemas negativos, apenas o método de identificação é possível [2].

A Figura 2.1 ilustra a arquitetura de um sistema biométrico generalizado. O uso de sistemas biométricos consiste em duas etapas: registro e autenticação. O registro é a etapa em que a característica biométrica da pessoa que está usando pela primeira vez o sistema é processada e registrada. Já a autenticação, é a etapa em que uma pessoa cadastrada disponibiliza a característica biométrica para o sistema de forma a verificar se é ou não registrada.

Cada um dos blocos do diagrama apresentado na Figura 2.1 são explicados nas Seções 2.2.1 até 2.2.5.

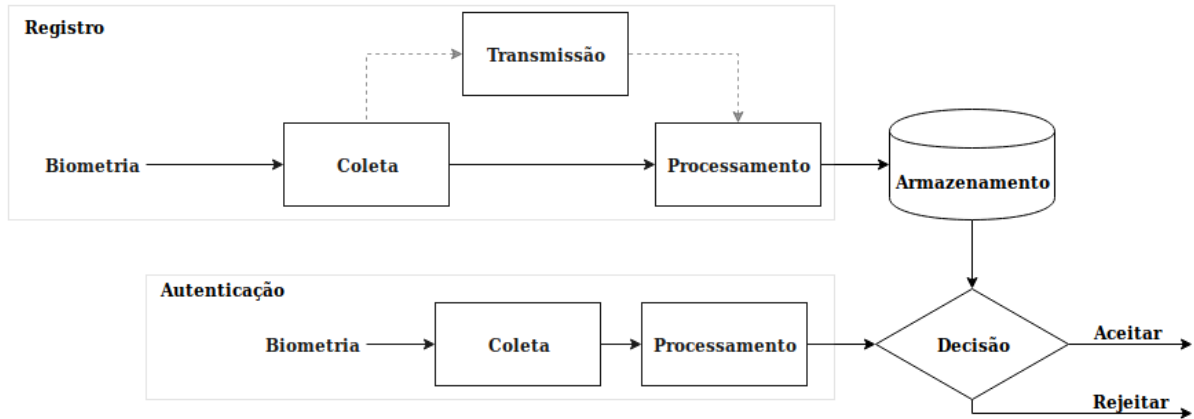


Figura 2.1: Arquitetura de um sistema biométrico genérico. Linhas contínuas indicam módulos obrigatórios e linhas tracejadas indicam módulos opcionais.

2.2.1 Módulo de Coleta

Módulo de sistemas biométricos responsável por capturar sinais de uma característica biométrica por meio de um sensor eletrônico [2]. O resultado apresentado pelo sensor, que vai ser posteriormente processado, é a combinação de três fatores: a medida biométrica, a maneira com que a medida é apresentada (imagem, áudio, vídeo) e os parâmetros técnicos do sensor. Se qualquer um dos três fatores sofre modificação, o desempenho do sistema é impactado.

A Figura 2.2 ilustra alguns modelos de sensores eletrônicos utilizados para capturar impressões digitais e íris, respectivamente.



(a) Sensor *Futronic FS80H* (Fonte: [28]).



(b) Sensor *LG IrisAccess 4000* (Fonte: [29, 3]).

Figura 2.2: Sensores biométricos de impressão digital e íris.

2.2.2 Módulo de Transmissão

O módulo de transmissão é responsável por transmitir a característica biométrica capturada pelo sensor no módulo de *Coleta* para ser processada e armazenada [2]. Esse

módulo não precisa estar presente em todo sistema biométrico, apenas os que processam e armazenam os modelos gerados no módulo de *processamento* remotamente.

O tamanho dos dados da característica biométrica capturada podem variar, mas geralmente são grandes, podendo causar gargalos na transmissão e ocupar muito espaço de armazenamento. Portanto, técnicas de compressão de dados podem ser aplicadas, para acelerar a transmissão e reduzir o espaço de armazenamento no banco de dados. A compressão, no entanto, introduz desafios, porque podem causar perda da qualidade dos dados e podem influenciar diretamente nos resultados do módulo de *Processamento* e, conseqüentemente, no módulo de *Decisão*. De forma a reduzir o impacto da compressão, técnicas específicas são aplicadas para cada tipo de característica biométrica.

2.2.3 Módulo de Processamento

O módulo de processamento consiste em segmentar, extrair os atributos e gerar o modelo da característica biométrica capturada no módulo de coleta [2].


A segmentação é a etapa responsável por encontrar e separar a característica biométrica no sinal de entrada capturado pelo sensor [2]. A Figura 2.3 ilustra os resultados da etapa de segmentação de impressão digital e de uma íris, respectivamente.

A extração de atributos é a etapa que recebe a característica biométrica segmentada, ignora os ruídos causados pelo sensor, transmissão ou a própria segmentação e a reduz a uma representação matemática com base em seus padrões, comumente chamados de modelos ou *templates* [2].

Na etapa de registro do sistema, esses *templates* são salvos e associados à pessoa sendo cadastrada em algum banco de dados. Na etapa de autenticação, os *templates* salvos são comparados com o *template* sendo autenticado no módulo de *decisão*.



(a) Impressão digital segmentada (Fonte: [30]).



(b) Íris segmentada (Fonte: [5]).

Figura 2.3: Resultados da segmentação de uma íris e impressão digital.

2.2.4 Módulo de Armazenamento

O módulo de armazenamento é o responsável por armazenar os *templates* das características biométricas geradas no registro de uma pessoa no sistema. Pode ou não ser um banco de dados centralizado, dependendo da aplicação [2].

Em sistemas que utilizam a funcionalidade de identificação é mais comum a utilização de bancos de dados centralizados, enquanto em sistemas de verificação é mais comum o uso de cartões para armazenar o *template*.

2.2.5 Módulo de Decisão

O módulo de decisão consiste na comparação dos *templates* de características biométricas armazenadas com o *template* gerado na etapa de autenticação e na decisão se há ou não correspondência para aceitar ou rejeitar a pessoa sendo autenticada no sistema [2].

A comparação pode ser feita usando métricas de diferença ou similaridade dos *templates*, e varia para cada sistema. Considerando uma distância ou similaridade a decisão é feita por meio de um limiar. O valor do limiar a ser utilizado no sistema depende da aplicação. Há aplicações de risco e que não podem permitir impostores, de forma que o limiar deve ser mais criterioso. Enquanto há aplicações que não é desejado que pessoas cadastradas sejam negadas frequentemente e, portanto, o limiar pode ser menos criterioso.

2.3 Processamento de Imagens no Domínio Espacial

Imagem digital é uma representação bidimensional de uma imagem, e corresponde à uma matriz de elementos, chamados *pixels* [31]. *Pixels* são os menores elementos de uma imagem digital, e seus valores recebem o nome de *intensidade de pixel* [31]. Como uma imagem pertence ao plano $2D$, o termo domínio espacial refere-se à própria imagem. A Equação 2.1 é a representação matemática de uma imagem, onde x e y são inteiros e correspondem à posição dos *pixels* na matriz [31]

$$I_{x,y} = \begin{bmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,y} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,y} \\ \vdots & \vdots & \ddots & \vdots \\ a_{x,1} & a_{x,2} & \cdots & a_{x,y} \end{bmatrix}. \quad (2.1)$$

Processar imagens no domínio espacial consiste em aplicar métodos ou operações (T) que modifiquem os valores dos *pixels* diretamente, conforme a Equação 2.2 [31]:

$$I_{saida}(x, y) = T[I_{entrada}(x, y)]. \quad (2.2)$$

As Subseções 2.3.1 até 2.3.3 detalham algumas técnicas de processamento de imagens no domínio espacial que serão importantes nesse projeto.

2.3.1 *Padrões Binários Locais (LBP)*

LBP é um método que propõe descritores binários invariantes à rotação para a textura de imagens monocromáticas [32]. O método consiste em percorrer os *pixels* da imagem de entrada, calcular propriedades da textura local de cada vizinhança do *pixel* referência com raio $R > 0$ e gerar um histograma que mapeia a textura de toda a imagem.

As Equações 2.3 a 2.4 demonstram como o *LBP* e o histograma de textura são calculados, respectivamente [32][33].

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p, s(x) = \begin{cases} 1 & s \geq 0 \\ 0 & s < 0 \end{cases} \quad (2.3)$$

A Equação 2.3 é aplicada para cada *pixel* da imagem de entrada, onde g_c é o valor do *pixel* central da vizinhança sendo calculada, g_p o valor do *pixel* dos vizinhos, P o total de vizinhos e R o raio da vizinhança. As coordenadas de g_p são calculadas pela fórmula $(R\cos(2\pi p/P), R\sin(2\pi p/P))$.

O histograma de textura é calculado de acordo com a equação Equação 2.4:

$$H(k) = \sum_{i=1}^I \sum_{j=1}^J f(LBP_{P,R}(i, j), k), k \in [0, K], \quad (2.4)$$

$$f(x, y) = \begin{cases} 1 & x = y \\ 0 & \text{caso contrário} \end{cases},$$

onde I e J são a quantidade de linhas e colunas da imagem de entrada, respectivamente, e K o valor máximo do *LBP*.

LBP é bastante utilizado em técnicas de classificação e aplicações em que a textura da imagem é um atributo essencial, como por exemplo [32]:

- Sensoreamento remoto;
- Análise de imagens médicas;
- Inspeção industrial de superfície;
- Qualidade de imagens.

2.3.2 Filtro *Variância Local*

O filtro *Desvio Padrão Local* consiste em um filtro de domínio espacial que calcula o desvio padrão local de cada *pixel* da imagem de entrada [34]. O filtro *Variância Local* é, portanto, uma variação do filtro de *Desvio Padrão Local*, que calcula a variância ao invés do desvio padrão.

O filtro de *Variância Local* consiste em calcular a variância da vizinhança, dado um elemento estruturante, ao redor do *pixel* de entrada e atribuí-la ao *pixel* de saída, conforme a Equação 2.5:

$$I_{saida}(x, y) = \frac{1}{N} \sum_{i=1}^N (v_i^{I_{entrada}(x,y)} - \mu)^2, \quad (2.5)$$

onde N é o número total de vizinhos sendo considerados, $v_i^{I_{entrada}(x,y)}$ são os valores de cada vizinho e μ a média da vizinhança. $I_{saida}(x, y)$ e $I_{entrada}(x, y)$ são o valor do *pixel* em determinada posição, x e y , das imagens de entrada e saída, respectivamente. Essa operação é feita em todos os *pixels* da imagem de entrada.

O filtro *Desvio Padrão Local* é útil para encontrar bordas de objetos em imagens. A Figura 2.4 ilustra uma imagem de entrada e a Figura 2.5 os resultados da filtragem dessa imagem pelos filtros de desvio padrão e variância, respectivamente.






Figura 2.4: Imagem de entrada.



(a) Com filtro *Desvio Padrão Local*.



(b) Com filtro *Variância Local*.

Figura 2.5: Resultados da filtragem da Figura 2.4 usando os filtros *Desvio Padrão Local* e *Variância Local*.

2.3.3 Método *Otsu*

Método *Otsu* é um algoritmo usado para encontrar um limiar que melhor separa duas classes em um histograma [35].

O cálculo é feito de forma que a variância dentro da mesma classe é mínima e, conseqüentemente, a variância entre as classes é máxima. As Equações 2.6 a 2.10 demonstram matematicamente os cálculos feitos em cada etapa do algoritmo. Nas equações, $\{0, 1, 2, \dots, L - 1\}$ são todos os L possíveis valores do histograma, p_i as probabilidades em que esses valores aparecem e t o limiar sendo considerado para os cálculos. O limiar T vai ser algum valor no intervalo $0 < T < L - 1$. As etapas do algoritmo são descritas abaixo:

1. Calcular o histograma e as probabilidades de cada valor do histograma;
2. Para cada $t = 0$ até $L - 1$:
 - (a) Atualizar as probabilidades e as médias de cada classe;
 - (b) Calcular a variância entre as classes;
3. Escolher o limiar T de forma que seja a maior variância calculada.

$$\omega_1(t) = \sum_{i=0}^{t-1} p(i), \quad (2.6)$$

$$\omega_2(t) = \sum_{i=t}^{L-1} p(i), \quad (2.7)$$


$$\sigma_b^2(t) = \omega_1(t)\omega_2(t)(\mu_1 - \mu_2)^2, \quad (2.8)$$

$$\mu_1(t) = \frac{1}{\omega_1(t)} \sum_{i=0}^{t-1} ip(i), \quad (2.9)$$


$$\mu_2(t) = \frac{1}{\omega_2(t)} \sum_{i=t}^{L-1} ip(i), \quad (2.10)$$

onde $\omega_1(t)$ e $\omega_2(t)$ são as probabilidades de cada classe; $\sigma_b^2(t)$ a variância entre as duas classes; e $\mu_1(t)$ e $\mu_2(t)$ as médias das classes.

Sua principal aplicação é em processamento de imagens, e consiste em binarizar imagens em escala de cinza. A binarização é feita calculando o histograma da imagem e então encontrando o limiar (intensidade de *pixel*) que melhor separa o fundo e o primeiro plano das imagens [31]. A Figura 2.6 ilustra imagens antes e depois da binarização utilizando o método *Otsu*.



(a) Imagem original.



(b) Imagem binarizada.

Figura 2.6: Processo de binarização de imagens utilizando o método *Otsu*.

2.4 Processamento Morfológico de Imagens

Morfologia matemática é o estudo de estruturas geométricas. Operações morfológicas aplicadas em imagens consistem no processamento de regiões baseados em suas formas [31].

A operação consiste em aplicar um elemento estruturante em uma imagem de entrada de forma a gerar uma imagem de saída. Os elementos estruturantes são matrizes e podem ter vários formatos e tamanhos, sendo círculos e quadrados os mais utilizados.

O elemento estruturante é sobreposto em todos os *pixels* da imagem, de forma que todos os elementos com valor 1 no elemento são considerados na região sobreposta da imagem. Para todo elemento estruturante, é atribuído um *ponto âncora*, que é o *pixel* da região sobreposta da imagem de entrada processado. A Figura 2.7 ilustra um elemento estruturante.

0	1	0
1	<u>0</u>	1
0	1	0

Figura 2.7: Exemplo de elemento estruturante. O elemento central sublinhado é o *ponto âncora*.

Operações morfológicas são aplicadas em imagens geralmente para [36]:

- Isolar elementos individuais;
- Juntar elementos que podem ser do mesmo objeto;

- Remover ruídos;
- Achar buracos ou sobreposições.

As duas principais operações morfológicas são a dilatação e erosão, e são explicadas nas Seções 2.4.1 e 2.4.2, respectivamente.

2.4.1 Dilatação

Operação morfológica que aumenta regiões mais claras, ou diminui regiões mais escuras, da imagem de entrada [31]. Pode ser utilizada também para calcular máximos locais de imagens.

O elemento estruturante é sobreposto em cada um dos *pixels* da imagem de entrada, o máximo local da região sobreposta é calculado, e, por fim, esse máximo é atribuído à imagem de saída na *posição âncora* do elemento estruturante. A Figura 2.8 ilustra as etapas descritas acima, considerando o elemento estruturante da Figura 2.7.

180	181	181	183	183
185	198	255	190	190
200	199	<u>255</u>	250	195
201	200	199	251	195
202	201	200	200	196

Figura 2.8: Resultado da etapa de dilatação. A matriz 3x3 centralizada corresponde ao elemento estruturante e o elemento sublinhado ao *ponto âncora* substituído pelo máximo valor da região sobreposta.

A Figura 2.9 ilustra uma imagem de entrada para a operação de dilatação e a imagem de saída resultante, respectivamente.

2.4.2 Erosão

Operação morfológica que diminui regiões mais claras, ou aumenta regiões mais escuras, da imagem de entrada [31]. Pode ser utilizada também para calcular mínimos locais de imagens.

Possui procedimentos parecidos com a operação de dilatação, mas ao invés de calcular os máximos das regiões sobrepostas pelo elemento estruturante, calcula os mínimos.



Figura 2.9: Imagem de entrada e saída da operação de dilatação (Fonte: [36]).

A Figura 2.10 ilustra uma imagem de entrada para a operação de erosão e a imagem de saída resultante, respectivamente.



Figura 2.10: Imagem de entrada e saída da operação de erosão (Fonte: [36]).

2.5 Filtragem de Imagens

Filtros são processos que modificam sinais de entrada. Como imagens são sinais, o processo de filtrar imagens consiste em modificá-las [31]. Filtros podem ser usados para remover componentes indesejados, realçar componentes desejados ou até para extrair informações ou atributos do sinais sendo processados [37].

Imagens podem ser filtradas tanto no domínio do espaço quanto da frequência. A filtragem no domínio espacial consiste em realizar o processo de convolução $2D$ por meio de filtros espaciais, chamados de máscaras ou *kernel*[38]. A convolução $2D$ pode ser representada matematicamente pela Equação 2.11:

$$g(x, y) = \sum_{s=-a}^a \left(\sum_{t=-b}^b H(s, t) I(x - s, y - t) \right), \quad (2.11)$$

onde g é a convolução, H o *kernel* e I a imagem sendo filtrada[31]. A Equação 2.12

$$g = I * H, \quad (2.12)$$

é a definição do operador de convolução.

Já a filtragem no domínio da frequência, consiste apenas na multiplicação da imagem e do *kernel* transformados para o domínio da frequência pela *Transformada de Fourier* ($F(\cdot)$) [31]. A Equação 2.13

$$I * H \iff F(I) \cdot F(H) \quad (2.13)$$

ilustra a relação entre as filtrações nos dois espaços.

Filtragem no domínio da frequência é útil quando deseja-se remover ou realçar um intervalo de frequências da imagem.

2.5.1 *Filtro Log-Gabor*

O filtro *Log-Gabor* é uma adaptação do filtro *Gabor*, mas na escala logarítmica, e é um filtro linear passa banda [39, 40]. Possui duas características que o diferem: não possui componentes *DC* e não pode ser representado por uma máscara no domínio do espaço, de forma que é exclusivo ao domínio da frequência [37]. Assim como o filtro *Gabor*, é muito utilizado para a extração de atributos e codificação de íris [40].

A função de ativação do filtro *Log-Gabor* é representada pela Equação 2.14:

$$H(\omega) = e^{\frac{-\log(\omega/\omega_0)^2}{2\log(\sigma)^2}}, \quad (2.14)$$

onde σ controla a largura de banda e ω_0 a frequência central do filtro. Já a Figura 2.11, ilustra a função de ativação do filtro na escala linear.




Figura 2.11: Função de ativação do filtro *Log-Gabor* na escala linear.

2.6 Sistemas Biométricos de Íris

Sistemas biométricos de íris são sistemas que utilizam algoritmos de reconhecimento de íris para autenticação biométrica. O uso de íris possuem inúmeras vantagens e desvantagens para seu uso, como listadas abaixo [41]:

Vantagens:

- Órgão protegido;
- Padrões possuem alta distintividade;
- Padrões são imutáveis ao longo da vida;
- A velocidade de processamento do módulo de *decisão* é rápida.

Desvantagens:

- Precisa ser capturada em distâncias pequenas;
- Olho em movimento atrapalha a etapa de segmentação;
- Cílios, pálpebras e reflexos atrapalham a etapa de segmentação;
- A dilatação da pupila pode eliminar alguns padrões da íris.

A Seção 2.6.1 define a estrutura da íris e suas funções; a Seção 2.6.2 discute as diferenças, as vantagens e desvantagens do uso de imagens de olho *Perto do Infravermelho (NIR)* e *Luz Visível (LV)* em sistemas de reconhecimento de íris; e por fim, a Seção 2.6.3 explica como algoritmos de reconhecimento de íris funcionam.

2.6.1 Olho humano

Íris é um órgão do globo ocular e é caracterizada por ser a parte circular colorida e pigmentada do olho humano [42]. Possui músculos que, ao contrair e dilatar a pupila, controlam a quantidade de luz que entra na retina [43]. A Figura 2.12 ilustra a íris, pupila, retina e as outras estruturas do olho humano.

A íris apresenta alta variedade de padrões e colorações, que podem variar do azul, castanho, verde, avelã até o cinza. A cor da íris é definida geneticamente, enquanto os padrões são desenvolvidos durante a gestação [4, 43]. A íris do olho esquerdo de um indivíduo é necessariamente diferente da do olho direito [2]. Essa diferença é ilustrada nas Figuras 2.13a a 2.13b.

Com a probabilidade de 1 em 10^{72} de existirem padrões de íris iguais e não modificarem ao longo da vida, é considerada um dos melhores tipos de biometria [45].




Figura 2.12: Anatomia de um olho humano (Fonte: [44]).



(a) Íris do olho direito.



(b) Íris do olho esquerdo.

Figura 2.13: Diferença das íris do olho humano (Fonte: [1]).

2.6.2 *Imagens Luz Visível (LV) vs Perto do Infravermelho (NIR)*

Espectro eletromagnético é o intervalo de ondas que são caracterizadas por comprimento de onda, frequência e energia [31]. A Figura 2.14 ilustra o espectro de ondas eletromagnéticas.




Figura 2.14: Espectro de ondas eletromagnéticas (Fonte: [46]).



(a) Pigmentação escura.



(b) Pigmentação clara.

Figura 2.15: Imagens de íris *LV* (Fonte: [1]).

Imagens *LV* são imagens capturadas por aparelhos, como câmeras fotográficas comuns, que possuem comprimento de onda no intervalo 430-790 *nm* no espectro eletromagnético, e é o intervalo perceptível pelo olho humano [31].

Já imagens *NIR* são imagens que possuem comprimento de onda no intervalo 800-900 *nm* no espectro eletromagnético [31]. O olho humano não é capaz de perceber esse intervalo no espectro eletromagnético, mas câmeras fotográficas especiais são capazes de capturá-las e registrá-las, de forma que possibilitam o estudo de suas propriedades [47].

Imagens *LV* de íris ilustram todas as suas possíveis variações de cores, citadas na Seção 2.6.1. Porém, alguns dos padrões da íris acabam sendo perdidos ou tendo qualidade ruim, especialmente de íris de cores mais escuras, já que os padrões também apresentam coloração escura. Imagens de íris *NIR* diminuem o efeito dos reflexos e da perda de padrões em imagens de íris escuras, além de destacarem os padrões da íris [10]. Por conta dessas propriedades, imagens *NIR* são as mais utilizadas em sistemas de reconhecimento de íris [4]. As Figuras 2.15 e 2.16 ilustram imagens de íris *LV* com pigmentação escura e clara, e imagem de íris *NIR*, respectivamente.



Figura 2.16: Imagem de íris *NIR* (Fonte: [48]).

2.6.3 Reconhecimento de íris

Algoritmos de reconhecimento de íris são algoritmos que implementam técnicas de segmentação, codificação e correspondência para identificar indivíduos usando suas íris [2, 4].

Como explicado na Seção 2.2.3, o módulo de *processamento* de um sistema biométrico consiste em duas etapas: segmentar e extrair os atributos da característica biométrica.

Algoritmos de segmentação de íris consistem, geralmente, na implementação dos seguintes passos [4, 40]:

1. Encontrar os raios e as posições do centro da íris e da pupila;
2. Normalizar a íris.

Algoritmos de segmentação geralmente utilizam o *Operador Integro-Diferencial (OID)* para encontrar as posições centrais e os raios da íris e pupila [4]. O operador consiste em uma fórmula que detecta as bordas circulares e é usado separadamente para a íris e a pupila. O OID é descrito pela Equação 2.15

$$OID = \max_{(r,x_0,y_0)} \left| G_\sigma(r) * \frac{\partial}{\partial r} \oint_{r,x_0,y_0} \frac{I(x,y)}{2\pi r} ds \right|, \quad (2.15)$$

e é aplicado por toda a imagem até que um formato circular é encontrado, onde $I(x, y)$ é a imagem com um olho humano, $\frac{\partial}{\partial r}$ a derivada parcial com relação aos valores do raio, \oint_{r,x_0,y_0} a integral de superfície para encontrar o formato circular, $2\pi r$ o contorno da imagem, r e (x_0, y_0) o raio e a posição do central da imagem inicialmente e G_σ é um filtro *Gaussiano* usado para suavizar ruídos.

O passo de normalização é feito de forma a transformar a imagem da íris segmentada para dimensões fixas e para a extração dos atributos e, geralmente, consiste na utilização do *Modelo Rubber Sheet* [4]. Esse modelo transforma a imagem da íris segmentada das coordenadas cartesianas para polares $(x, y) \mapsto (\rho, \theta)$. A Figura 2.17 ilustra o procedimento realizado pelo *Modelo Rubber Sheet* e a Figura 2.18b uma imagem de íris normalizada com esse modelo. Nessa etapa, uma máscara binária da imagem normalizada também é gerada, de forma a separar íris de ruídos e ser utilizada no módulo de *decisão*.





Figura 2.17: Procedimento do *Modelo Rubber Sheet* (Fonte: [49]).

A extração de atributos em reconhecimento de íris recebe o nome de codificação [4]. A etapa de codificação consiste, geralmente, na aplicação das *Wavelets 2D de Gabor* na imagem da íris normalizada, de forma a gerar um código de íris (*IrisCode*) único, que é o modelo ou *template* da característica biométrica [50]. *Wavelets 2D de Gabor* extraem



(a) Imagem original antes da normalização.



(b) Imagem de íris normalizada.

Figura 2.18: Processo de normalização de uma imagem de íris segmentada.

atributos da íris como uma sequência de vetores com números *complexos* e então usa os ângulos de suas fases para quantizar uma sequência de dois *bits* dependendo do quadrante no plano *complexo*, conforme a Figura 2.19 [4]. São extraídos no total do processo, 2048 *bits* (256 *bytes*) [4]. A Figura 2.20 ilustra uma imagem de íris segmentada com o seu *IrisCode*.




Figura 2.19: Codificação pelos quadrantes do plano *complexo* das *Wavelets 2D de Gabor* (Fonte: [4]).

As *Wavelets 2D de Gabor* são calculadas pela Equação 2.16:

$$h\{Re, Im\} = sgn_{\{Re, Im\}} \int_{\rho} \int_{\phi} I(\rho, \phi) e^{-i\omega(\theta_0 - \phi)} \cdot e^{-(r_0 - \rho)^2 / \alpha^2} e^{-(\theta_0 - \phi)^2 / \beta^2} \rho d\rho d\phi, \quad (2.16)$$

em que $h\{Re, Im\}$ é um valor complexo em que tanto a parte real quanto imaginária pode ser 0 ou 1, dependendo do sinal (*sgn*) da integral; $I(\rho, \phi)$ é a imagem da íris normalizada nas coordenadas polares; α e β são parâmetros de tamanho da *wavelet 2D*; ω a frequência da *wavelet*; e por fim, r_0 e θ_0 são as coordenadas da imagem da íris na coordenada polar sendo calculadas.




Figura 2.20: Imagem segmentada e seu *IrisCode* gerado (Fonte: [51]).

A Seção 2.2.5 detalha o módulo de *Decisão* de um sistema biométrico que consiste no cálculo da diferença ou similaridade de dois *templates* gerados no módulo de *Processamento* de forma a verificar se há ou não correspondência entre eles.

Em reconhecimento de íris, essa comparação é feita, geralmente, pelo cálculo da diferença entre os *IrisCodes* e as máscaras binárias das imagens normalizadas pela *Distância Hamming (HD)* fracional [4].

O cálculo da *HD* é feito pela Equação 2.17:

$$HD = \frac{\|(\text{código}A \otimes \text{código}B) \cap \text{máscara}A \cap \text{máscara}B\|}{\|\text{máscara}A \cap \text{máscara}B\|}, \quad (2.17)$$

em que *código* e *máscara* A e B são os códigos e máscaras sendo comparadas; \otimes e \cap são as operações *booleanas XOR* e *AND*; e $\| \cdot \|$ são as normas dos vetores de *bits*. O resultado dessa equação são valores entre 0 e 1, onde 0 é uma correspondência perfeita [4].

No próximo capítulo é realizada uma revisão de artigos que implementaram métricas de qualidade de imagem e é explicado com mais detalhes as métricas de qualidade escolhidas para a implementação deste projeto: *Índice de Sinal-Magnitude Diferencial (DSMI)* e *Avaliação da Correlação de Atributos (FCE)*.

Capítulo 3

Revisão Bibliográfica

Neste capítulo, uma revisão bibliográfica de métricas de qualidade de imagem, imagens biométricas, imagens de íris e da segmentação de íris é feita e os métodos das métricas *Índice de Sinal-Magnitude Diferencial (DSMI)* e *Avaliação da Correlação de Atributos (FCE)* são explicados com detalhes.

Este projeto consiste na aplicação de duas métricas de qualidade, *DSMI* [12] e *FCE* [18], e na verificação de como elas influenciam no desempenho de sistemas de reconhecimento de íris.

Qualidade de imagens é um tema que tem grande destaque na comunidade científica, por suas muitas aplicações, como sistemas biométricos, transmissão, compressão, restauração entre outras [52]. Possui diversos desafios, principalmente porque qualidade é algo subjetivo e sujeito à percepção de seres humanos [53].

Muitos algoritmos de medição foram implementados tentando objetificar a medição de qualidade de imagens e são separados em três categorias [53]: *Referência Completa (FR)*, *Referência Reduzida (RR)* e *Sem Referência (NR)*. Algoritmos *FR* e *RR* consistem em algoritmos que precisam completa ou parcialmente de uma imagem referência para calcular qualidade de imagens, enquanto algoritmos *NR* ou *Avaliação de Qualidade de Imagens Sem Referência (NR-IQA)* são os mais vantajosos porque não precisam de imagens referência. Neste projeto, foi escolhido usar algoritmos *NR-IQA*.

Pelo desafio e vantagens, grandes avanços têm sido feitos no estudo de algoritmos de qualidade de imagem *NR-IQA*, como os trabalhos seguintes: Os autores de [54] e [55] projetaram os algoritmos *Índices de Qualidade de Imagens Cegos (BIQI)* e *Qualidade baseada em Entropia Espacial-Espectral (SSEQ)*, respectivamente, onde os dois implementam estruturas de dois passos e técnicas de aprendizado de máquina para calcular a qualidade de imagens *NR*. Jenadeleh *et al.* [56, 57] propuseram dois algoritmos *NR-IQA*, um que utiliza estatísticas para calcular um vetor de atributos com informações de qualidade e usar o vetor para treinar um modelo de aprendizado de máquina; e outro que calcula

a qualidade de imagens baseado em atributos de estatísticas de imagens derivadas de múltiplos domínios e atributos de estética de imagens e os usa para tentar melhorar o desempenho de algoritmos *NR-IQA* estado da arte. Os autores de [52] elaboraram um algoritmo *NR-IQA* que calcula *Modelos Multivariados Gaussianos (MVG)* de fragmentos de imagens e os usam para calcular a qualidade de imagens. Todos os algoritmos descritos acima apresentam bom desempenho, mas são limitados por precisarem de rotulações subjetivas e manuais para treinar os modelos de aprendizado de máquina.

Algoritmos de métricas de qualidade foram implementados para acessar a qualidade de características biométricas que são representadas em imagens, de forma a melhorar o desempenho de sistemas biométricos. Mohamad *et al.* [58] implementaram uma métrica de qualidade de rosto, impressão digital e veias de mãos que consiste no uso de um modelo de aprendizado de máquina que é alimentado com a combinação de dois tipos de informação: qualidade da imagem e padrões extraídos pelo descritor *SIFT* [59]. Os autores de [60] propuseram um algoritmo de qualidade de imagens de impressão digital que usa um modelo de aprendizado de máquina para detectar rótulos de qualidade da impressão digital e calcular uma nota para sua qualidade. Wasnik *et al.* [61] implementaram uma métrica de qualidade de imagens de rosto baseado em densidade de bordas verticais para fotos de *smartphones*.

Com o objetivo de melhorar o desempenho de sistemas de reconhecimento de íris, métricas de qualidade foram implementadas. Essas métricas de qualidade podem medir a qualidade de uma imagem de íris ou a qualidade da etapa de segmentação.

Os algoritmos implementados pelos autores Daugman, Starvoitov *et al.* e Wan *et al.* [4, 11, 13] consistem em métricas de qualidade de imagens de íris considerando ruídos relacionados ao foco da imagem; o algoritmo [14] consiste na proposta de uma métrica para avaliar os efeitos de compressão *JPEG* e evitá-los; o algoritmo [15] propõe uma métrica que avalia a nitidez de imagens de íris usando o operador *Brenner* em *Regiões de Interesse (ROI)* definidas. Pelos algoritmos [4, 11, 13, 14, 15] funcionarem apenas para tipos específicos de ruídos, são considerados limitados. Kalka *et al.* [16] e Li *et al.* [17] implementaram métricas de qualidade de imagens de íris que consideram ruídos como desfoco, reflexo e imagens sem ângulo, entre outros. Esses dois algoritmos avaliam um maior número de ruídos, mas foram implementados exclusivamente para imagens de íris *NIR*. Jenadeleh *et al.* [12] propuseram uma métrica de qualidade de imagens de íris *LV*, chamada *DSMI*, que usa estatísticas de sinal e magnitude da imagem para calcular sua qualidade, considerando os ruídos mais comuns em imagens *LV* e de íris. O algoritmo apresentou bons resultados em seus testes e demonstrou não possuir limitações como os outros algoritmos descritos acima para avaliar a qualidade de imagens de íris.

Belcher *et al.* [19] implementaram o algoritmo *Métrica Seletiva de Informação dos*

Atributos (SFIM) para calcular a qualidade da etapa de segmentação de sistemas de reconhecimento de íris de imagens *NIR*, que leva em conta fatores como oclusão, dilatação da pupila e a qualidade dos padrões presentes na área da íris segmentada. Assim como a métrica proposta por [19], a métrica implementada por [20] calcula a qualidade da etapa de segmentação de sistemas de reconhecimento de íris por meio da análise de formatos flexíveis para a íris e a pupila. Os autores de [7] implementaram uma métrica para calcular a qualidade de imagens de íris *LV* e da sua segmentação que considera os ruídos de foco, movimento, ângulo, oclusões, dilatação e nível de pigmentação da íris a partir da íris segmentada. Ma *et al.* [21] também calcularam a qualidade da íris por meio do resultado da segmentação e usaram a distribuição da orientação horizontal de duas subregiões da íris em conjunto com um modelo de aprendizado de máquina.

O algoritmo *FCE* foi proposto por Du *et al.* [18] para corrigir inconsistências presentes na etapa do algoritmo *SFIM* que calcula a qualidade dos padrões da íris, e apresentou melhorias no desempenho de sistemas de reconhecimento de íris.

No geral, os algoritmos *DSMI* e *FCE* apresentaram os melhores resultados, ao melhorarem consideravelmente sistemas de reconhecimento de íris, considerarem os principais ruídos que afetam imagens de íris e por serem algoritmos computacionalmente eficientes. Por essas razões, foram as métricas de qualidade escolhidas para a análise em sistemas de reconhecimento de íris.

As Seções 3.1 e 3.2 explicam com mais detalhes as métricas *DSMI* e *FCE*, respectivamente.

3.1 *Índice de Sinal-Magnitude Diferencial (DSMI)*

Índice de Sinal-Magnitude Diferencial (DSMI) é uma métrica de qualidade de imagens de íris cujo objetivo é avaliar se a imagem de entrada de um sistema de reconhecimento de íris é boa o suficiente para a etapa de segmentação [12].

A métrica é uma adaptação do algoritmo *Padrões Binários Locais Completos (CLBP)* [33] e consiste no cálculo de atributos estatísticos locais que dividem a imagem em dois componentes, sinal (S_1) e magnitude (S_2), e então os combinam (S) de forma a calcular uma nota para uma imagem de íris em *Luz Visível (LV)* [12].

A imagem de entrada do algoritmo deve ser convertida para escala de cinza e normalizada pela Equação 3.1

$$\hat{I} = \frac{I - I_{min}}{I_{max} - I_{min}}. \quad (3.1)$$

Os padrões são calculados considerando uma vizinhança de 4 pixels (verticais e horizontais) e considerando todos os *pixels* da imagem, menos os das bordas. Nas equações abaixo, $\hat{I}(r)$ são os *pixels* da imagem sendo processados e $\hat{I}(v)$ seus vizinhos.

O componente de sinal S_1 consiste no cálculo dos máximos locais da imagem de entrada, conforme a Equação 3.2 [12]:

$$S_1 = \begin{cases} 1, & \hat{I}(r) > \max(\hat{I}(v)) \\ 0, & \text{caso contrário} \end{cases}. \quad (3.2)$$

O componente de magnitude S_2 é calculado pela comparação de um limiar T com a máxima diferença absoluta dos máximos locais com seus vizinhos segundo a Equação 3.3 [12]:

$$S_2 = \begin{cases} 1, & T > \max(|\hat{I}(r) - \hat{I}(v)|) \\ 0, & \text{caso contrário} \end{cases}. \quad (3.3)$$

O limiar T é calculado em toda a imagem normalizada, e consiste na média das diferenças absolutas dos *pixels* que são máximos locais e seus vizinhos, conforme a Equação 3.4 [12]:

$$T = \frac{1}{N} \sum_{m \in M} |\hat{I}(m) - \hat{I}(v)|, \quad (3.4)$$

em que M são todos os máximos locais encontrados no cálculo do componente S_1 .

As estatísticas do sinal S_1 e magnitude S_2 são combinadas na estatística de coincidência de padrões S , segundo a Equação 3.5 [12]:

$$S = S_1 \cap S_2, \quad (3.5)$$

onde \cap é a operação *booleana* AND.

A variância das vizinhanças da imagem é calculada para ser usada no cálculo da qualidade final, conforme a Equação 3.6 [12]:

$$\sigma^2 = \text{var} \hat{I}(v). \quad (3.6)$$

A qualidade final da imagem de íris é calculada pela Equação 3.7 [12]:

$$Q_{DSMI} = r \left(\frac{1}{W \cdot H} \sum_{c \in C} \frac{S(c)}{\sigma^2(c) + \delta^2} \right), \quad (3.7)$$

onde c são todos os pixels da imagem, menos as bordas, W é a quantidade de colunas, H a quantidade de linhas da imagem de entrada, S são as estatísticas de sinal e magnitude

combinadas, σ^2 a variância da vizinhança de todos os pixels e r se trata da função que normaliza a nota da qualidade.

A função de normalização r é definida na seguinte Equação 3.8 [12]:

$$r : [0, \infty) \rightarrow [0, 1) \quad x \mapsto 1 - e^{-ax}, \quad (3.8)$$

onde aos parâmetros δ^2 e a são atribuídos os valores 0.00025 e 0.01, respectivamente. Esses valores foram encontrados pelos autores do artigo [12].

3.2 Avaliação da Correlação de Atributos (FCE)

Avaliação da Correlação de Atributos (FCE) é uma métrica que avalia a qualidade da etapa de segmentação em sistemas de reconhecimento de íris em imagens *Perto do Infravermelho (NIR)* [18]. Apesar de ter sido implementado e testado para imagens *NIR*, os autores afirmam em [26] que o algoritmo funciona também para imagens *LV*.

A métrica tem o objetivo de medir a qualidade da segmentação da íris e consiste na fusão de três métricas: métrica da correlação dos atributos, métrica da oclusão e métrica da dilatação da pupila [18].

A métrica de correlação dos atributos avalia a qualidade e a distintividade dos padrões presentes na íris segmentada, ao medir a correlação entre os atributos vizinhos usando distância de informação. Possui duas etapas: filtragem e o cálculo da métrica.

Inicialmente, a imagem da íris normalizada resultante da etapa de segmentação passa por uma etapa de filtragem. Cada linha da imagem é transformada para o domínio da frequência e passa por um processo de filtragem, usando o filtro passa banda *Log-Gabor* unidimensional, que é descrito pela Equação 2.14. As linhas são então transformadas de volta para o domínio espacial.

As operações que são feitas entre duas linhas consecutivas, \vec{l}_i e \vec{l}_{i+1} , na magnitude da imagem resultante da etapa de pré processamento são descritas nas Equações 3.9 a 3.12 [18]:

$$\vec{p} = \frac{\vec{l}_i}{\sum \vec{l}_i}, \quad (3.9)$$

$$\vec{q} = \frac{\vec{l}_{i+1}}{\sum \vec{l}_{i+1}}, \quad (3.10)$$

$$J(\vec{p}, \vec{q}) = D(\vec{p} \parallel \vec{q}) + D(\vec{q} \parallel \vec{p}), \quad (3.11)$$

$$D(\vec{x} \parallel \vec{y}) = \sum_n \vec{x}_n \log_2 \frac{\vec{x}_n}{\vec{y}_n}, \quad (3.12)$$

onde \vec{p} e \vec{q} são as funções massa de probabilidade das linhas consecutivas da imagem filtrada, $J(\vec{p}, \vec{q})$ a distância de informação e $D(\vec{x} \parallel \vec{y})$ a entropia relativa [62].

Por fim, a média dessas distâncias de informação é calculada para cada par consecutivo de linhas da imagem filtrada para resultar na medida de correlação dos atributos, conforme a Equação 3.13 [18]:

$$FCM = \frac{1}{N-1} \sum_i J_{i,i+1}, \quad (3.13)$$

onde N é o número de linhas da imagem normalizada.

O cálculo da métrica que avalia a qualidade dos padrões das íris, representado pela Equação 3.13, que foi a mudança feita pelos autores em relação à métrica *SFIM* [19]. A métrica *SFIM* compara elementos das linhas da imagem filtrada nas coordenadas polares com suas distribuições uniformes e selecionam aquelas com maior diferença para o seu cálculo. Essa abordagem causa sensibilidade a elementos introduzidos por técnicas de compressão, fazendo com que notas altas sejam calculadas para imagens comprimidas com qualidade inferior. Portanto, a mudança foi implementada para reduzir os efeitos dos padrões artificiais produzidos pela compressão e deixar a métrica de qualidade final mais robusta.

A métrica de oclusão é calculada para minimizar a influência de ruídos com cílios, pálpebra e reflexos no cálculo da qualidade final da segmentação. Essa métrica usa as máscaras binárias resultantes da etapa de normalização da íris segmentada, conforme a Equação 3.14 [18]

$$O = \frac{\text{Área de ruídos na máscara binária}}{\text{Tamanho total da máscara binária}}. \quad (3.14)$$

A métrica de dilatação é calculada porque a dilatação da pupila pode diminuir a área de íris válida, como ruídos, e influenciar negativamente na qualidade final. A medida é calculada pela Equação 3.15 [18]:

$$D = \frac{R_p}{R_i}, \quad (3.15)$$

onde R_p e R_i são os raios da pupila e íris, respectivamente.

A qualidade final é calculada pela combinação das três métricas *FCM*, *O* e *D*, conforme a Equação 3.16 [18]:

$$Q_{FCE} = f(FCM) \cdot g(O) \cdot h(D). \quad (3.16)$$

As Equações 3.17 a 3.19 descrevem as funções de normalização das métricas [18]:

$$f(FCM) = \begin{cases} \alpha \cdot FCM & 0 \leq FCM \leq \beta \\ 1 & FCM > \beta \end{cases} \quad (3.17)$$

onde $\beta = 0.005$ e $\alpha = a/\beta$;

$$g(O) = (1 - e^{-\lambda(1-O)})/\kappa \quad (3.18)$$

onde $\lambda = 2.5$ e $\kappa = 0.9179$;

$$h(D) = \begin{cases} 1 & D \leq 0.6 \\ e^{-\gamma(D-\zeta)} & 0.6 < D \leq 1 \end{cases} \quad (3.19)$$

onde $\gamma = 40$ e $\zeta = 0.6$.

Os parâmetros β e α da Equação 3.17, λ e κ da Equação 3.18, e γ e ζ da Equação 3.19 são encontrados pelos autores do artigo.

No próximo capítulo, será explicado a metodologia utilizada para o desenvolvimento do projeto e como as métricas *DSMI* e *FCE* foram implementadas.

Capítulo 4

Metodologia

Este capítulo descreve os métodos para a implementação do projeto proposto. São mostrados o diagrama da arquitetura do sistema de reconhecimento de íris com as métricas $DSMI$ e FCE , e cada um dos módulos ou blocos desse diagrama.

4.1 Arquitetura proposta

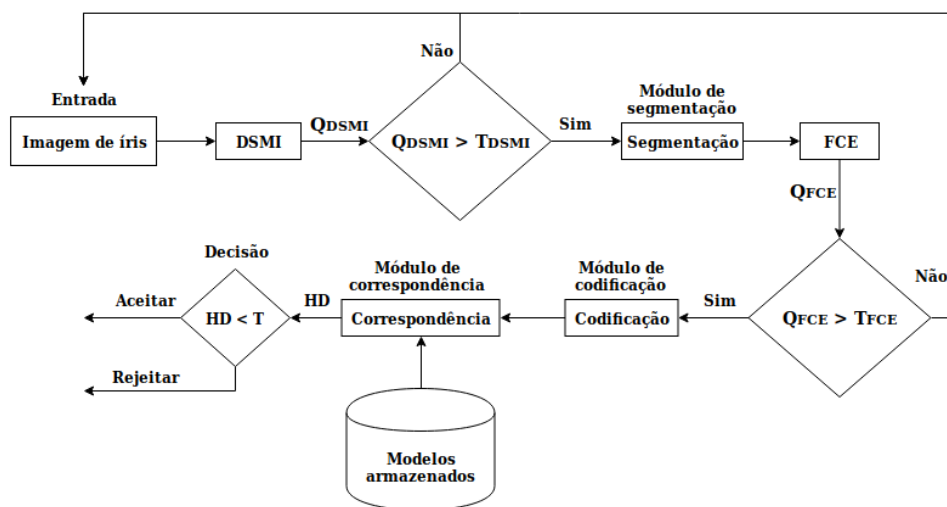


Figura 4.1: Diagrama da arquitetura de sistema de reconhecimento de íris com as métricas de qualidade $DSMI$ e FCE proposta. T_{DSMI} é o limiar definido para a métrica $DSMI$, T_{FCE} o limiar da métrica FCE e T o limiar para aceitar ou rejeitar um indivíduo que está sendo autenticado a partir da *Distância Hamming* (HD) calculada entre seus modelos.

A Figura 4.1 ilustra o diagrama da arquitetura proposta. O funcionamento da arquitetura proposta consiste em filtrar imagens de íris e segmentações com baixa qualidade em dois pontos do sistema: o primeiro antes da etapa de segmentação e o segundo entre

as etapas de segmentação e codificação. O processo de filtragem de imagens com baixa qualidade é feito calculando a sua qualidade (Q_{DSMI}) com a métrica $DSMI$ e o processo de filtragem de íris segmentadas com baixa qualidade é feito pelo cálculo da sua qualidade (Q_{FCE}) pela métrica FCE .

A arquitetura proposta foi projetada para ser flexível, de forma que qualquer sistema de reconhecimento de íris pudesse ser usado. Essa flexibilidade possibilita o uso de diversos algoritmos de segmentação, codificação e correspondência de íris, contanto que suas saídas sejam compatíveis com as métricas $DSMI$ e FCE , e que o resultado da correspondência seja uma distância.

Como o objetivo do projeto é a análise das métricas na taxa de desempenho de sistemas de reconhecimento de íris, o sistema de reconhecimento de íris *OSIRISv4.1* [6, 63, 64] foi utilizado na arquitetura proposta, e a etapa de registro foi desconsiderada no diagrama da Figura 4.1, já que somente a análise da etapa de autenticação é necessária porque foram utilizados bancos de dados de imagens de íris. Para utilizar o *OSIRISv4.1*, devem ser criados quatro arquivos de configurações [64]:

1. Segmentação;
2. Correspondência;
3. Pontos de aplicação;
4. Filtros de *Gabor*.

No arquivo de segmentação devem ser passados parâmetros para o funcionamento dos algoritmos, um arquivo texto do computador que contém uma lista de imagens de íris para ser processadas, o diretório que contém as imagens e o diretório em que as saídas do *OSIRISv4.1* vão ser armazenadas. O arquivo de correspondência precisa de uma lista com pares de imagens de íris que já foram processadas pelo sistema e o arquivo de texto que o resultado das comparações será salvo, que consiste na HD calculada para os pares de imagens. Os arquivos de pontos de aplicação e filtros de *Gabor* são disponibilizados em [63] e os autores recomendam que sejam os usados.

No Capítulo 5 é detalhado como os limiares T_{DSMI} , T_{FCE} e T da Figura 4.1 foram obtidos. Cada um dos blocos ou módulos apresentados na Figura 4.1 são detalhados nas Seções 4.1.1 até 4.1.5.

4.1.1 DSMI

O módulo DSMI consiste no módulo responsável pelo cálculo da qualidade da imagem de íris de entrada no sistema proposto, pela métrica $DSMI$. O módulo deve receber como

entrada uma imagem de íris LV , calcular sua qualidade e decidir se a imagem está adequada para continuar para o próximo módulo. A Figura 4.2 ilustra o módulo e os passos descritos acima.




Figura 4.2: Representação do módulo da métrica de qualidade $DSMI$ no diagrama da arquitetura proposta. A entrada é uma imagem de íris LV e saída é a qualidade da imagem Q_{DSMI} , sendo um valor entre 0 e 1. Enfim, o módulo deve decidir se a imagem é ou não boa o suficiente com base no limiar T_{DSMI} .

O componente de sinal S_1 consiste no cálculo dos máximos locais da imagem de entrada (Equação 3.2) e o componente de magnitude S_2 na comparação de um limiar global T com as máximas diferenças locais (Equação 3.3). Os passos para calcular os máximos locais e as máximas diferenças seguem os seguintes passos:

1. Obter imagem resultante, nomeada *Maximas*, do processamento da imagem de entrada com a operação morfológica de dilatação (Seção 2.4.1), considerando a vizinhança vertical e horizontal (elemento estruturante da Figura 2.7);
2. Obter imagem resultante, chamada de *Minimas*, do processamento da imagem de entrada com a operação morfológica de erosão (Seção 2.4.2), considerando a vizinhança vertical e horizontal (elemento estruturante da Figura 2.7);
3. Calcular as absolutas diferenças entre as imagens *Maximas* e a imagem de entrada, conforme: $X = |I_{entrada} - Maximas|$;
4. Calcular as absolutas diferenças entre a imagem de entrada e a imagem *Minimas*, conforme: $Y = |Minimas - I_{entrada}|$;
5. Comparar os *pixels* da imagem de entrada com o equivalente da imagem *Maximas*, e verificar se é maior, se for, é um máximo local e 1 é atribuído à posição em S_1 (Equação 3.2);
6. Calcular $\max(X, Y)$ de forma a obter as máximas diferenças em uma matriz, chamada de *MaxDiffs*, da imagem de entrada.

Com os máximos locais encontrados, o limiar T usado para calcular os componentes de magnitude S_2 é calculado conforme a Equação 3.4, para então calcular S_2 .

A estatística da coincidência dos padrões S é calculada de acordo com a Equação 3.5. A variância das vizinhanças dos *pixels* da imagem de entrada σ^2 (Equação 3.6) é calculada por meio do filtro de *Variância Local* (Seção 2.3.2) com a máscara (*kernel*) representada pela Figura 2.7.

Com S e σ^2 , a qualidade final Q_{DSMI} é, por fim, calculada conforme a Equação 3.7 e normalizada pela Equação 3.8. O módulo decide então se a imagem é ou não boa o suficiente para ser segmentada comparando o limiar T_{DSMI} com a qualidade Q_{DSMI} .

4.1.2 Segmentação

O módulo de segmentação é o módulo responsável por segmentar e normalizar a imagem de íris de entrada no sistema. O módulo deve receber a imagem de íris que passou pelo módulo DSMI, segmentá-la e normalizá-la, resultando nos parâmetros: raio e posição central da íris e da pupila, onde (X, Y, R) são as coordenadas da posição e o raio, respectivamente; máscara binária da íris segmentada; íris normalizada em coordenadas polares; e a máscara binária da imagem normalizada. Nas máscaras binárias, os *pixels* pretos são ruídos como pálpebras e cílios, e os *pixels* brancos são íris corretamente segmentadas. A Figura 4.3 ilustra o módulo e as entradas e saídas do módulo.




Figura 4.3: Módulo que segmenta e normaliza a imagem de íris. As etapas de segmentação e normalização são divididas em dois blocos separados, de forma que qualquer algoritmo de segmentação ou normalização pudesse ser usado. Sua entrada consiste na imagem de íris LV e suas saídas são as posições centrais e raio da íris e pupila, máscaras binárias da íris e da íris normalizada, e a íris normalizada.






Figura 4.4: Imagem de íris LV .



(a) Íris e pupila segmentadas.



(b) Máscara binária resultante da íris segmentada.

Figura 4.5: Íris da Figura 4.4 segmentada. Os valores encontrados para (X_p, Y_p, R_p) e (X_i, Y_i, R_i) foram: $(419, 274, 52)$ e $(414, 276, 183)$, respectivamente.

A etapa de segmentação do *OSIRISv4.1* consiste em dois passos: encontrar a posição central da pupila e seu raio para então encontrar a íris [64]. A pupila é encontrada seguindo dois critérios: (i) calcular o valor mínimo na imagem sendo filtrada por uma máscara de raio r , onde o processo de filtragem é a soma da vizinhança considerada pela máscara; (ii) calcular os gradientes verticais e horizontais da imagem usando o operador *Sobel* [65], construir duas máscaras de raio r , filtrar os gradientes com as duas máscaras construídas e encontrar o valor máximo da soma do resultado das duas filtragens. Os critérios (i) e (ii) são repetidos para vários valores de raio da pupila r , e o valor máximo do resultado das somas dos dois critérios representa o melhor candidato para a pupila. Os contornos da íris, então, devem ser encontrados usando o algoritmo *Viterbi* [66]. O algoritmo é aplicado em duas resoluções: altas e baixas. A resolução alta é usada para encontrar os contornos precisos da íris e a resolução baixa para os contornos grosseiros (*coarse contours*). O centro da íris e seu raio são calculados pelos procedimentos descritos acima. O intervalo de valores dos raios que devem ser usados para procurar a íris e pupila são passados por arquivos de configuração, conforme descrito em [64]. Os valores utilizados neste projeto são enumerados no Capítulo 5, porque variaram para cada base de dados utilizada nos experimentos. A Figura 4.5 ilustra os resultados da etapa de segmentação da imagem Figura 4.4.

A etapa de normalização do *OSIRISv4.1* é feita usando os contornos grosseiros encontrados na etapa de segmentação em conjunto com o *Modelo Rubber Sheet* (Seção 2.6.3) [64]. Os valores das dimensões da imagem normalizada devem ser passados por arquivos de configuração, conforme descrito em [64]. Os valores utilizados neste projeto são: 40 linhas e 300 colunas, ou seja, 40×300 . A Figura 4.6 ilustra os resultados da etapa de normalização da imagem Figura 4.4.



Figura 4.6: Íris da Figura 4.4 normalizada.

4.1.3 FCE

O módulo FCE é o módulo que é responsável por calcular a qualidade da segmentação da íris da imagem de entrada, usando a métrica de qualidade FCE . O módulo recebe os resultados do módulo de segmentação, calcula a qualidade da segmentação e decide se a segmentação foi boa, de forma a ser passada para o módulo de codificação. A Figura 4.7 ilustra as entradas e saídas do módulo FCE.




Figura 4.7: Módulo da métrica de qualidade FCE que calcula a qualidade da segmentação da íris. Recebe como entrada a íris e a máscara normalizadas e os raios da pupila e íris. A saída consiste na qualidade da segmentação Q_{FCE} , sendo um valor entre 0 e 1. O módulo deve então decidir se a segmentação da íris foi boa o suficiente para ser codificada, de acordo com o limiar T_{FCE} .

A métrica consiste no cálculo de três submétricas, conforme descrito na Seção 3.2:

1. Métrica de Correlação dos Atributos;
2. Métrica de oclusão;
3. Métrica de dilatação,

em que a métrica de correlação dos atributos (FCM) consiste na medição da qualidade e a distintividade dos padrões presentes na íris segmentada, métrica de oclusão (O) na medição da quantidade de ruídos presentes na íris segmentada e a métrica de dilatação (D) na medição de quanto a pupila está dilatada. As métricas são então combinadas na qualidade final da segmentação Q_{FCE} .

Para o cálculo da métrica FCM , é necessária a imagem da íris normalizada. Os passos descritos abaixo são feitos para cada par adjacente de linhas da imagem da íris normalizada, \vec{l}_i e \vec{l}_{i+1} , conforme descrito pelas Equações 3.9 a 3.12 na Seção 3.2:

1. Filtrar as linhas \vec{l}_i e \vec{l}_{i+1} com o filtro *Log-Gabor* (Equação 2.14);

2. Calcular a função de massa probabilidade das linhas \vec{l}_i e \vec{l}_{i+1} filtradas (Equações 3.9 a 3.10);
3. Calcular a distância de informação J_i com as entropias relativas e armazená-la em um vetor (Equação 3.11);

Quando os passos enumerados acima forem repetidos para todas as linhas da imagem de íris normalizada, FCM é calculado pela média das distâncias de informação J_i (Equação 3.13). Os parâmetros utilizados no filtro Log-Gabor na Equação 2.14 são: $\omega_0 = 22$ e $\sigma = 0.5$. Para o cálculo da métrica final, FCM é normalizado pela função $f()$ (Equação 3.17). Como a métrica foi proposta para imagens no espectro *NIR* [18], e o projeto proposto trabalha com imagens no espectro de luz visível, o parâmetro β foi recalculado com imagens de treino dos bancos de imagens utilizados no projeto, de forma que experimentalmente $\beta = 0.294$ foi obtido. Já o parâmetro α continua sendo $\alpha = 1/\beta$.

A métrica de oclusão O precisa da máscara binária normalizada da íris para ser calculada e o cálculo consiste em somar todos os *pixels* pretos e dividir pela quantidade total de *pixels* da imagem, conforme a Equação 3.14. A métrica O deve então ser normalizada pela função $g()$ (Equação 3.18).

A métrica de dilatação D precisa dos raios da pupila e íris e o seu cálculo consiste simplesmente em aplicar a Equação 3.15. A função de normalização $h()$ (Equação 3.19) é então aplicada.

Enfim, a qualidade final Q_{FCE} é calculada pela Equação 3.16 e o módulo decide se a íris segmentada é apropriada para o módulo de codificação, comparando o limiar T_{FCE} com a qualidade Q_{FCE} .

4.1.4 Codificação

O módulo de codificação é o módulo responsável por codificar os atributos extraídos da íris segmentada e gerar o código da íris (*IrisCode*). O módulo deve receber a íris normalizada em coordenadas polares, resultado do módulo de segmentação, e codificá-la por meio de algum algoritmo e gerar o *IrisCode* correspondente. A Figura 4.8 ilustra o módulo e as suas entradas e saídas.

A etapa de codificação do *OSIRISv4.1* consiste na aplicação de três filtros *Gabor*. Porém, como a parte real e imaginária são consideradas independentemente, acabam sendo seis processos de filtragem [64]. Os resultados das seis filtrações passam pelo processo das *Wavelets 2D de Gabor* (Seção 2.6.3), de forma que 6 imagens binárias, ou 6 códigos de íris, são combinados em um único *IrisCode*. A Figura 4.9 ilustra o *IrisCode* gerado para a íris da Figura 4.4. Os filtros de *Gabor* utilizados são fornecidos em [63] pelos autores no formato de um arquivo de configuração.



Figura 4.8: Módulo que codifica a íris segmentada. As etapas de extração dos atributos e codificação são divididas em dois submódulos. Sua entrada consiste na íris normalizada em coordenadas polares, resultado do módulo de segmentação, e sua saída é o código da íris (*IrisCode*).




Figura 4.9: *IrisCode* da Figura 4.4 gerado pelo *OSIRISv4.1*. Pode-se notar que são 6 códigos de íris combinados em um só, para cada um dos filtros *Gabor* aplicados.

4.1.5 Correspondência

O módulo de correspondência é o último módulo do sistema proposto e é responsável por calcular a distância entre dois códigos de íris e decidir se o sistema deve ou não aceitar a autenticação. O módulo deve receber dois códigos de íris e as máscaras binárias normalizadas correspondentes e usá-los para calcular a *Distância Hamming (HD)* (Seção 2.6.3). A Figura 4.10 ilustra o módulo e as suas entradas e saídas.

A etapa de correspondência do *OSIRISv4.1*, assim como a usada pelo autor [4], consiste no cálculo da *HD* usando dois códigos de íris e duas máscaras binárias, mas os métodos utilizados para o seu cálculo são diferentes no *OSIRISv4.1* [64]. O cálculo consiste em fazer a operação *booleana AND* entre as duas máscaras binárias em posições específicas, definidas pelos pontos de aplicação. Então, a operação *booleana XOR* é feita entre os dois códigos de íris nas posições dos pontos de aplicação que o resultado da operação entre as máscaras é 1, ou seja, não é ruído. Quanto menor o valor resultante, maior a probabilidade dos dois códigos de íris pertencerem à mesma pessoa. Os pontos de aplicação são definidos




Figura 4.10: Módulo que calcula a *Distância Hamming (HD)* entre dois modelos e decide se correspondem ou não a mesma pessoa. O módulo recebe como entrada dois *IrisCodes* e duas máscaras binárias normalizadas correspondentes, A e B. Então calcula a *HD* seguindo a Equação 2.17, e a compara com o limiar T definido para o sistema e, caso seja menor, aceita a autenticação e rejeita caso contrário.

em um arquivo de configuração e são disponibilizados em [63] pelos autores. A Figura 4.11 ilustra os passos descritos acima para o cálculo da *HD*.

No próximo capítulo, serão descritos os experimentos realizados para validar as métricas *DSMI* e *FCE* na arquitetura proposta no diagrama da Figura 4.1.




Figura 4.11: Processos realizados para calcular a *Distância Hamming (HD)* entre os modelos obtidos dos processos de segmentação e codificação de um indivíduo. Operação *booleana AND* é feita entre duas máscaras binárias normalizadas em posições definidas nos pontos de aplicação. A operação *XOR* é então aplicada nos pontos de aplicação que não são ruídos, obtidos no resultado da operação *AND* (Fonte: [64]).

Capítulo 5

Resultados

Neste capítulo são apresentados os experimentos realizados para analisar a arquitetura proposta utilizando as duas métricas de qualidade: $DSMI$ e FCE . São introduzidos os bancos de imagens de íris LV ; os limiares T_{DSMI} e T_{FCE} calculados para os bancos de imagens; os ruídos artificiais aplicados nas imagens dos bancos de imagens para os experimentos; os resultados das segmentações de íris usando o algoritmo de segmentação do *OSIRISv4.1*; e, por fim, são apresentados os resultados dos experimentos utilizando três índices de desempenho de sistemas de reconhecimento de íris.

5.1 Bancos de imagens

Para a análise da arquitetura de sistema de reconhecimento de íris proposta com as duas métricas, $DSMI$ e FCE , foram utilizados quatro bancos de imagens de íris LV para as suas imagens as íris serem segmentadas, terem os códigos gerados e para serem efetuadas as correspondências:

1. *MICHE* [22, 67, 68];
2. *UBIRISv1* [23, 69];
3. *UBIRISv2* [24, 70];
4. *Warsaw-BioBase-Smartphone-Iris-v1.0 (Warsaw)* [1, 71].

De cada banco de imagens, foram selecionadas cinco imagens de 40 indivíduos aleatoriamente, porque era o número mínimo de indivíduos entre os bancos de imagens e o número de imagens mínimas entre os indivíduos. Dessas cinco imagens, 2 foram reservadas para treino e 3 para teste. As imagens de treino foram utilizadas para calcular os limiares T_{DSMI} e T_{FCE} de cada banco de imagens. Já as imagens de teste foram utilizadas

para o uso na arquitetura proposta e avaliar como as métricas de qualidade influenciaram no rendimento de sistemas de reconhecimento de íris. Foram selecionadas somente cinco imagens porque entre os bancos de imagens, é o número mínimo de imagens por indivíduo.

As Seções 5.1.1 até 5.1.4 explicam com mais detalhes e ilustram os bancos de imagens enumerados acima e na Seção 5.1.5 é explicado como os limiares foram calculados e os resultados obtidos.

5.1.1 *MICHE*

MICHE é uma base de dados de imagens de íris capturadas por *smartphones*, cujos objetivos são entregar uma larga quantidade de indivíduos, usar mais de um *smartphone* para capturar as imagens, simular situações reais em que as pessoas tiram as próprias fotos e sessões para a aquisição das imagens em tempos separados [67]. O banco de imagens contém imagens de 75 indivíduos, em que para cada pessoa, somente imagens de um dos olhos é capturada e pelo menos 4 imagens devem ser capturadas nos *smartphones*:

- *Galaxy Samsung IV*: 1297 imagens;
- *iPhone5*: 1262 imagens;
- *Galaxy Tablet II*: 632 imagens.

As imagens são capturadas pelos próprios voluntários, em que eles podem ou não estar de óculos, e são capturadas em distâncias e em dois ambientes diferentes: ao ar livre e em lugares fechados. As imagens do bancos de imagens são extremamente desafiadoras para algoritmos de segmentação, porque como os indivíduos da amostra que capturaram as imagens, ruídos como cabelo, fundo na imagem, problemas de foco, borrão em movimento e distorções de iluminação são recorrentes entre as imagens do banco de imagens.

Neste projeto, foram utilizadas somente as imagens capturadas pelo *smartphone iPhone5*, porque a sua câmera apresentou imagens com melhores resoluções em relação aos outros aparelhos.

A Figura 5.1 ilustra imagens sem a presença de ruídos do banco de imagens *MICHE* e capturadas em ambientes e distâncias diferentes. Já a Figura 5.2 ilustra imagens com distorções como óculos, cabelo e fundo.



Figura 5.1: Imagens sem a presença de ruídos do *MICHE*.




Figura 5.2: Imagens com distorções do *MICHE*.

5.1.2 *UBIRISv1*

UBIRISv1 é um banco de imagens de imagens de íris capturadas por câmera fotográfica com o objetivo de capturar imagens com vários ruídos, de forma a simular ambientes não controlados de aquisição [23, 69]. O banco de imagens possui imagens de 241 indivíduos, totalizando 1877 imagens. As imagens são capturadas pela câmera *Nikon E5700* e foram tiradas em duas sessões, onde:

- Primeira sessão: Imagens foram capturadas com o objetivo de minimizar ruídos, como reflexo, luminosidade e contraste, e a estrutura para capturar as imagens foi montada em uma sala sem a presença de luz natural;
- Segunda sessão: Local de captura foi mudado, para incorporar fatores de luminosidade natural, de forma que ruídos como reflexos, problemas de foco, contraste aparecem nas imagens.

Neste projeto, foram separadas imagens de 20 indivíduos da primeira sessão e 20 da segunda sessão.

As Figuras 5.3 e 5.4 ilustram imagens capturadas na primeira e segunda sessão dos mesmos indivíduos, respectivamente.



Figura 5.3: Imagens da primeira sessão do *UBIRISv1*.




Figura 5.4: Imagens da segunda sessão do *UBIRISv1*.

5.1.3 *UBIRISv2*

UBIRISv2 é um banco de imagens de imagens de íris dos mesmos autores do *UBIRISv1*, com o objetivo de deixar as imagens mais realistas, ou seja, com mais tipos de ruídos e em diversas distâncias [24]. O banco de imagens é composto por 11102 imagens distribuídas em 261 indivíduos. As imagens foram capturadas pela câmera *Canon EOS 5D*.

A captura de imagens foi dividida em duas sessões, onde somente a localização da câmera e o tipo de luz artificial no ambiente mudaram. Três imagens são capturadas em cinco distâncias diferentes da câmera, entre 4 e 8 metros, totalizando 15 imagens por indivíduo em cada sessão:

- 8 metros: I1-I3;
- 7 metros: I4-I6;
- 6 metros: I7-I9;
- 5 metros: I10-I12;
- 4 metros: I13-I15.

Foi solicitado aos indivíduos que olhassem para pontos diferentes no ambiente enquanto andavam lentamente entre as marcas das distância, de forma a capturar imagens da íris em ângulos diferentes e em movimento para introduzir ruídos.

No projeto, foram utilizadas somente imagens da primeira sessão do banco de imagens e imagens capturadas a 4 e 5 metros da câmera (I11-I15), por conta de algumas

restrições dos parâmetros de tamanho mínimo e máximo da pupila e íris do algoritmo de segmentação do sistema *OSIRISv4.1*.

A Figura 5.5 ilustra exemplos de imagens das cinco distâncias usadas do *UBIRISv2*.




Figura 5.5: Imagens do banco de imagens *UBIRISv2* capturadas a 5 e 4 metros da câmera.

5.1.4 *Warsaw*

Warsaw é um banco de imagens de imagens de íris capturadas por *smartphones* [1]. Tem o objetivo de propor imagens de íris de *smartphones* de boa qualidade e avaliar seu rendimento em sistemas de reconhecimento de íris conhecidos. Participaram do projeto 70 voluntários, em que a captura das imagens de suas íris esquerda e direita foi dividida em duas sessões e em ambientes fechados. As imagens foram capturadas pelo *smartphone iPhone 5s* e em todas, foi utilizada a câmera traseira com *flash*. No total, foram capturadas 3192 imagens de 139 íris esquerdas e 136 íris direitas dos 70 voluntários.

No projeto, foram utilizadas somente imagens da primeira sessão e os olhos foram selecionados alternadamente entre os indivíduos. Imagens da segunda sessão não foram utilizadas porque nem todos os indivíduos que participaram da primeira sessão participaram da segunda e em muitos casos, cada indivíduo só possuía de duas a quatro imagens por olho, quantidade insuficiente para os experimentos.

A Figura 5.6 ilustra imagens da primeira sessão do banco de imagens *Warsaw*.




Figura 5.6: As imagens (a)-(c) ilustram olhos esquerdos e (d)-(f) olhos direitos da primeira sessão do *Warsaw* de pessoas diferentes.

5.1.5 Limiares T_{DSMI} e T_{FCE}

Como os banco de imagens escolhidos para os experimentos possuem características diferentes, os limiares T_{DSMI} e T_{FCE} da arquitetura proposta (Figura 4.1) foram calculados separadamente para cada banco de imagens.

Para calcular o limiar T_{DSMI} foram usadas as duas imagens de treino de 40 indivíduos dos bancos de imagens, totalizando 80 por banco de imagens. As etapas para o cálculo do limiar de cada banco de imagens são enumeradas abaixo:

1. Calcular a métrica de qualidade $DSMI$ das 80 imagens;
2. Gerar o histograma das métricas calculadas;
3. O limiar T_{DSMI} consiste no limiar $Otsu$ (Seção 2.3.3) calculado a partir do histograma.

O cálculo do limiar T_{FCE} seguiu os mesmos passos descritos para o limiar T_{DSMI} , mas antes foram executadas as etapas de segmentação do *OSIRISv4.1* das 80 imagens de cada banco de imagens e ao invés de calcular a qualidade das imagens de íris usando a métrica $DSMI$, foram calculadas as qualidades das segmentações pela métrica de qualidade FCE . Os limiares calculados para cada banco de imagens são mostrados na Tabela 5.1.

Tabela 5.1: Valores dos limiares T_{DSMI} e T_{FCE} calculados para todos os bancos de imagens.

	<i>MICHE</i>	<i>UBIRISv1</i>	<i>UBIRISv2</i>	<i>Warsaw</i>
T_{DSMI}	0.75	0.83	0.69	0.51
T_{FCE}	0.54	0.85	0.54	0.9

O limiar de *Otsu* calcula o limiar que maximiza a variância entre duas classes (Seção 2.3.3). Pela Tabela 5.1, é possível notar como os valores encontrados para os dois limiares variaram para cada banco de imagens. O valor do limiar T_{DSMI} do *MICHE* é elevado, apesar de alguns ruídos presentes nas imagens e o valor do limiar T_{FCE} é baixo, porque as imagens foram incorretamente segmentadas pelo algoritmo de segmentação do *OSIRISv4.1*, que apresentou deficiências. Os limiares do banco de imagens *UBIRISv1* apresentaram valores condizentes, porque suas imagens são capturadas em condições apropriadas e controladas, e as íris foram corretamente segmentadas. O banco de imagens *UBIRISv2*, assim como o *MICHE*, é desafiador, porque as imagens apresentam ruídos e causam dificuldades para a segmentação, por conta das diferenças de distância que as imagens foram capturadas, como explicado na Seção 5.1.3, e apresentou valores de limiares esperados para suas condições. O limiar T_{DSMI} calculado para o banco de imagens *Warsaw* pode ser considerado baixo, mas é o que melhor separa as qualidades da métrica *DSMI* calculadas das imagens do banco de imagens e o limiar T_{FCE} apresentou um valor condizente, já que as imagens, no geral, tiveram suas íris corretamente segmentadas.

5.1.6 Ruídos

Conforme explicado na Seção 5.1, cinco imagens de 40 indivíduos foram escolhidas aleatoriamente em todos os bancos de imagens. Dessas cinco imagens, duas foram reservadas para o cálculo dos limiares T_{DSMI} e T_{FCE} e três para a análise do desempenho da arquitetura de sistema de reconhecimento de íris proposta usando as métricas *DSMI* e *FCE*.

Como a qualidade das imagens podem influenciar diretamente na segmentação de íris e três imagens de teste serem muito poucas para os experimentos, por conta da limitação que os bancos de imagens impuseram, foram geradas imagens com seis ruídos artificiais: *Desfoque Gaussiano*, *Impulso (Sal e Pimenta)*, *Ruído Branco Gaussiano (WGN)*, *Superexposição*, *Desfoque Móvel* e o padrão de compressão *JPEG2000*. Os cinco primeiros ruídos foram escolhidos porque são os ruídos mais comuns em imagens de íris e são utilizados nos experimentos da métrica *DSMI* [12] e o padrão de compressão *JPEG2000* é a utilizada nos experimentos da métrica *FCE* [18]. Para cada ruído, são usados quatro

parâmetros diferentes, de forma que são geradas quatro imagens ruidosas. Os ruídos são gerados para cada imagem de teste, de forma que para cada, 24 novas imagens são geradas e no final, totalizam 3000 imagens para serem usadas nos experimentos em cada banco de imagens. A Tabela 5.2 lista os ruídos com os parâmetros utilizados para gerá-los, em que neste projeto foi utilizado a linguagem de programação *MATLAB*. A Figura 5.7 ilustra exemplos de imagens de íris com os ruídos gerados.

Tabela 5.2: Ruídos gerados e os parâmetros utilizados

Ruídos	Parâmetros
<i>Desfoque Gaussiano</i>	$\sigma = 0.5, 2, 3.5, 5$
<i>Impulso (Sal e Pimenta)</i>	Densidade = 0.05, 0.2, 0.35, 0.5
<i>WGN</i>	$\mu = 0; \sigma^2 = 0.002, 0.008, 0.014, 0.02$
<i>Supereposição</i>	Constante = 10, 40, 70, 100
<i>Desfoque Móvel</i>	Comprimento, $\theta = 10, 26.66, 43.33, 60$
<i>JPEG2000</i>	Taxa de compressão = 25, 50, 75, 100

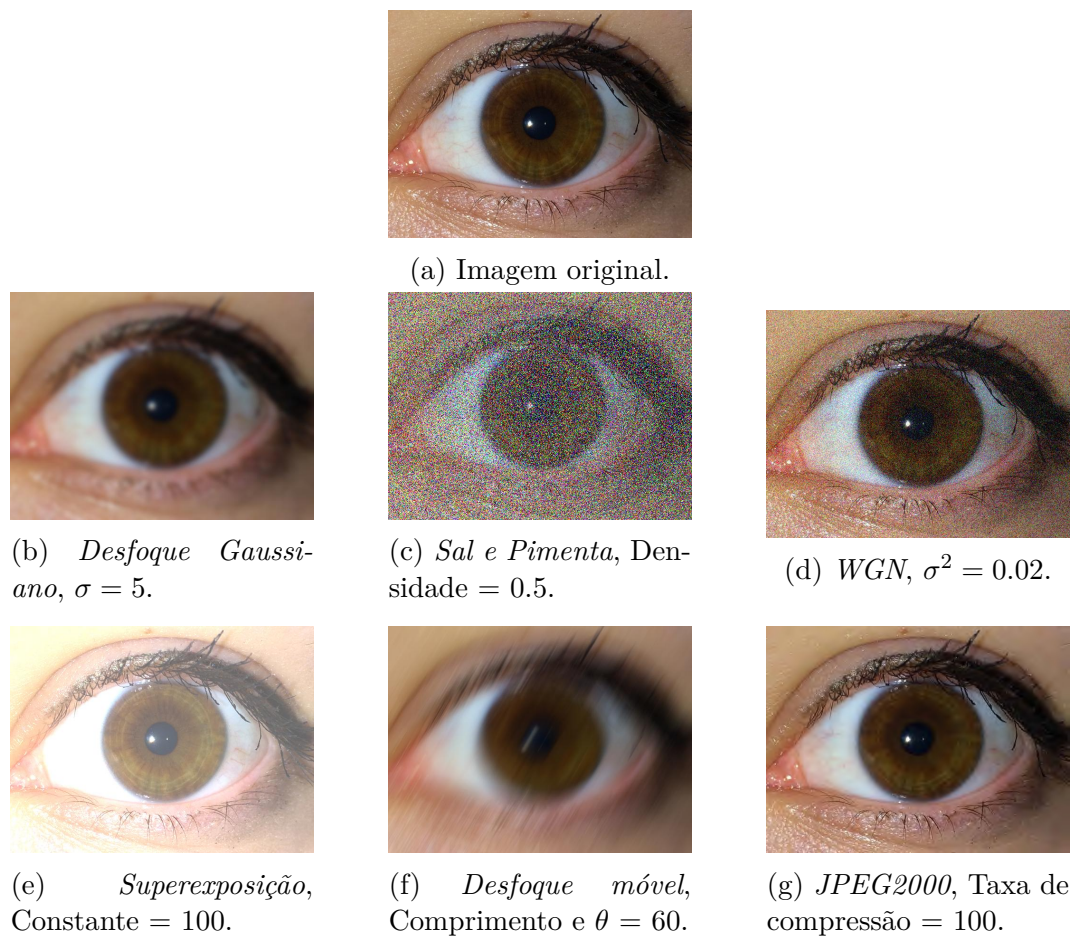


Figura 5.7: Imagem original e imagens resultantes para cada ruído.

5.2 Segmentação

O algoritmo de segmentação do *OSIRISv4.1* consiste em encontrar primeiro a pupila e depois encontrar os contornos da íris com base em intervalos de valores para os raios, como explicado na Seção 4.1.2. Em seus arquivos de configuração, devem ser passados quatro argumentos: diâmetros mínimos e máximos da pupila e íris. Os parâmetros utilizados no projeto são descritos nas Tabelas 5.3 e 5.4, onde na primeira são ilustrados os parâmetros utilizados nos bancos de imagens *MICHE*, *UBIRISv1* e *Warsaw*, enquanto na segunda os parâmetros utilizados no *UBIRISv2*.

Tabela 5.3: Parâmetros de diâmetros da pupila e íris usados no sistema *OSIRISv4.1* para os bancos de imagens *MICHE*, *UBIRISv1* e *Warsaw*.

	<i>MICHE</i>	<i>UBIRISv1</i>	<i>Warsaw</i>
Pupila (Min, Max)	(75, 160)	(80, 160)	(50, 200)
Íris (Min, Max)	(160, 500)	(160, 450)	(100, 400)

Tabela 5.4: Parâmetros de diâmetros da pupila e íris usados no sistema *OSIRISv4.1* para o banco de imagens *UBIRISv2*.

	I11	I12	I13 e I14	I15
Pupila (Min, Max)	(54, 77)	(60, 70)	(60, 70)	(40, 80)
Íris (Min, Max)	(99, 110)	(100, 120)	(100, 190)	(100, 200)

O algoritmo de segmentação do *OSIRISv4.1* apresentou algumas limitações, especialmente para imagens do banco de imagens *UBIRISv2*. O *OSIRISv4.1* exige valores mínimos para os parâmetros da pupila e íris, sendo 21 e 99 para os mínimos, e 91 e 399 para os máximos do diâmetro da pupila e íris, respectivamente. Esses valores mínimos e máximos são bons para imagens de íris com dimensões médias e altas, que não é o caso das imagens do *UBIRISv2*, que possuem dimensões de 400x300. Com essas dimensões, as íris e pupilas nas imagens possuem raios pequenos, de forma que provocou erros no algoritmo de segmentação do *OSIRISv4.1* ao tentar usar parâmetros gerais para o banco de imagens. A solução encontrada foi, como descrito na análise da Seção 5.1.5, escolher as imagens do *UBIRISv2* capturadas mais próximas da câmera, de forma que a pupila e a íris possuem raios com valores mais elevados (I11-I15), e utilizar parâmetros separados para cada imagem e distância.

Mesmo com as soluções propostas, as segmentações do *UBIRISv2* foram as que apresentaram os piores resultados, principalmente na segmentação da pupila. Além do *UBIRISv2*, as imagens do *MICHE* também apresentaram muitas íris incorretamente segmentadas, mas ao invés de ser por limitações do algoritmo de segmentação do *OSIRISv4.1*,

a qualidade das imagens influenciou negativamente, porque apresentavam cabelos, fundo e porque são capturadas em condições não controladas e pelas próprias pessoas. A Figura 5.8 ilustra os resultados do processo de segmentação dos bancos de imagens *MICHE*, *UBIRISv1* e *Warsaw*, enquanto a Figura 5.9 ilustra os resultados da segmentação do *UBIRISv2*.

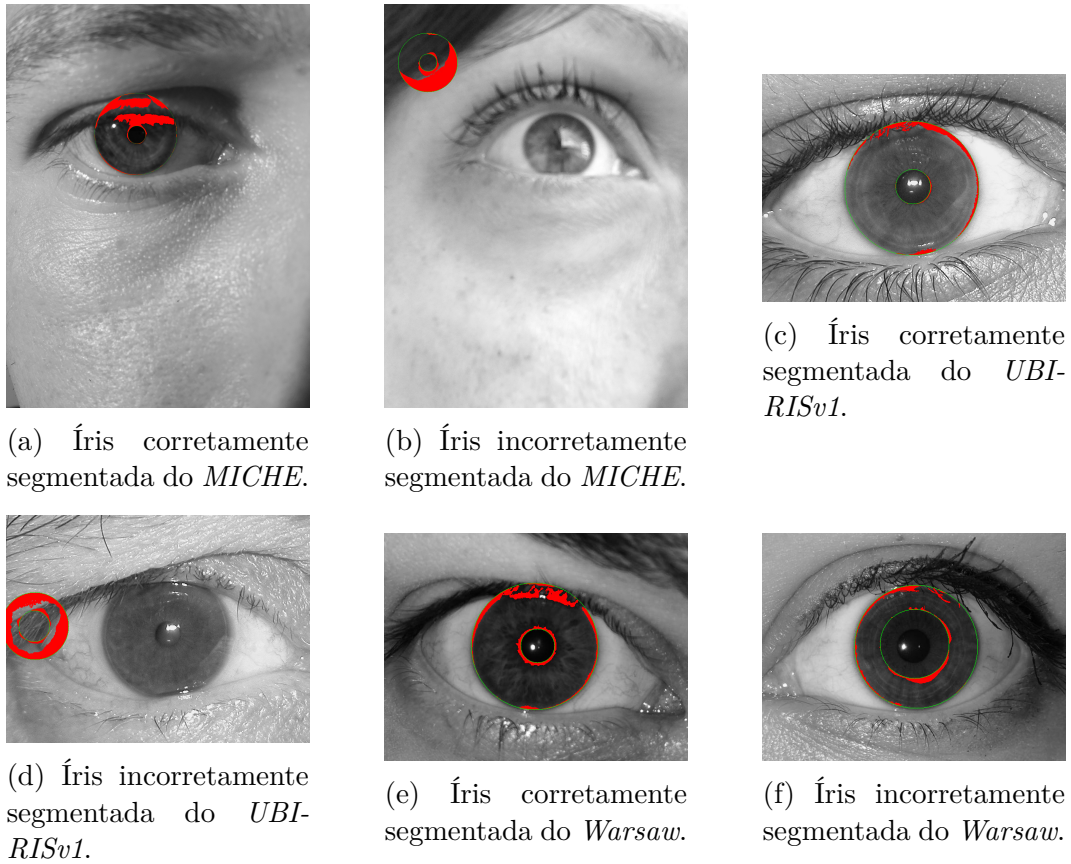


Figura 5.8: Resultados das segmentações de íris dos bancos de imagens *MICHE*, *UBIRISv1* e *Warsaw*.

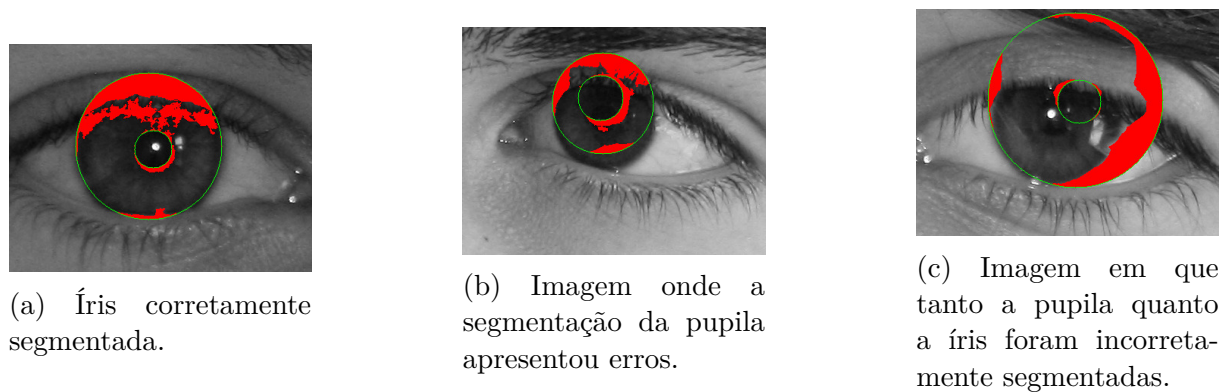


Figura 5.9: Resultados da segmentação do banco de imagens *UBIRISv2*.

5.3 Experimentos de Reconhecimento de Íris

Cinco etapas foram seguidas para a realização dos experimentos em cada um dos bancos de imagens, e consistiram em:

1. Executar a métrica *DSMI* em todas as imagens;
2. Segmentar, normalizar e codificar todas as íris das imagens com o *OSIRISv4.1*;
3. Executar a métrica *FCE* nos resultados da segmentação de todas as imagens;
4. Executar o algoritmo de correspondência do *OSIRISv4.1* com as *IrisCodes* geradas para as íris;
5. Aplicar os índices de rendimento de reconhecimento de íris nos resultados obtidos da correspondência das íris.

A implementação da métrica de qualidade *DSMI* foi feita utilizando a linguagem de programação *C++* com a biblioteca *OpenCV* [72], assim como os códigos obtidos do sistema de reconhecimento de íris *OSIRISv4.1*. A métrica de qualidade *FCE* e o cálculo dos índices de desempenho foram implementados na linguagem de programação *Python* com o auxílio das bibliotecas *Numpy* [73], *scikit-learn* [74] e *Matplotlib* [75].

Para analisar o rendimento da arquitetura de sistema de reconhecimento de íris proposta, foram utilizadas imagens originais e as ruidosas geradas para todos os bancos de imagens, como descrito na Seção 5.1.6, totalizando 3000 por banco de imagens.

Foram realizados quatro experimentos com as imagens para avaliar o rendimento de sistemas de reconhecimento de íris de forma a comparar com o sistema proposto:

- Sem nenhuma métrica (SM): sistema padrão, sem usar métricas de qualidade;
- Usando somente a métrica de qualidade *DSMI*;
- Usando somente a métrica de qualidade *FCE*;
- Usando as duas métricas (DM): Arquitetura proposta no projeto (Figura 4.1).

Como foram utilizadas as imagens dos bancos de imagens e não imagens capturadas em tempo real, os experimentos com métricas de qualidade não consistiram em rejeitar imagens e solicitar por novas, como descrito na arquitetura proposta. Ao invés de rejeitá-las, as imagens simplesmente eram descartadas dos cálculos de rendimento em cada um dos experimentos realizados. Para avaliar o desempenho dos quatro experimentos, os seguintes índices foram utilizados:

- *Área Sobre a Curva (AUC) e Característica do Operador do Receptor (ROC)* [76, 77, 78];
- *Taxa de Erro Igual (EER)* [76, 79];
- *Índice de Daugman (d')* [78].

5.3.1 *Área Sobre a Curva (AUC) e Característica do Operador do Receptor (ROC)*

Sistemas biométricos devem aceitar ou rejeitar um indivíduo a partir de comparações de seus modelos com modelos armazenados [2]. A decisão de aceitar ou rejeitar um indivíduo pode resultar em quatro resultados: o indivíduo é corretamente aceito ou rejeitado ou é incorretamente aceito ou rejeitado. O limiar de decisão do sistema biométrico influencia diretamente nesses resultados. De forma a medir a acurácia de sistemas biométricos, quatro taxas são usadas [78]:


1. *Taxa de Verdadeiro Positivo (TPR)*: Taxa de indivíduos que são corretamente aceitos pelo sistema;
2. *Taxa de Verdadeiro Negativo (TNR)*: Taxa de indivíduos que são corretamente rejeitados pelo sistema;
3. *Taxa de Falso Positivo (FPR)*: Taxa de indivíduos que são incorretamente aceitos pelo sistema;
4. *Taxa de Falso Negativo (FNR)*: Taxa de indivíduos que são incorretamente rejeitados pelo sistema.

ROC é um gráfico comumente usado para avaliar o desempenho de sistemas de reconhecimento de íris [77, 78]. O gráfico consiste na plotagem da *TPR* no eixo das ordenadas pela *FPR* no eixo das abcissas, que são calculadas para vários limiares de decisão. *AUC* é a métrica usada para avaliar o desempenho do sistema biométrico a partir do gráfico *ROC* e consiste em calcular a área sobre a curva do *ROC* [77]. A *AUC* quantifica as aceitações e rejeições de indivíduos em sistemas biométricos. Pode resultar em valores entre 0.5 e 1, e possuem as seguintes classificações [77]:


- Falha: 0.5 até 0.6;
- Pobre: 0.6 até 0.7;
- Justo: 0.7 até 0.8;

- Bom: 0.8 até 0.9;
- Excelente: 0.9 até 1.


A Figura 5.10 ilustra os gráficos *ROC* e suas *AUC* calculadas para os experimentos.




(a) *MICHE*.



(b) *UBIRISv1*.



(c) *UBIRISv2*.



(d) *Warsaw*.

Figura 5.10: Curvas *ROC* e *AUC* calculados para as imagens do experimento de cada banco de imagens. Nos gráficos, *Sem* são as *AUC* que foram calculadas sem nenhuma métrica de qualidade e *Ambas* significa *AUC* calculadas com as duas métricas de qualidade.

No banco de imagens *MICHE*, a arquitetura proposta com as duas métricas de qualidade não apresentou o melhor resultado no experimento. Usando somente a métrica *DSMI* apresentou a melhor *AUC*, mas o seu valor calculado, no entanto, é considerado somente justo [77], com valor no intervalo 0.7 a 0.8.

No banco de imagens *Warsaw*, a arquitetura proposta com as duas métricas obteve a melhor *AUC*. O resultado encontrado com a arquitetura proposta no experimento é excelente [77], porque apresenta *AUC* no intervalos 0.9 a 1.

Nos bancos de imagens *UBIRISv1* e *UBIRISv2*, a arquitetura proposta obteve os melhores resultados no experimento. A *AUC* calculada no *UBIRISv1* foi excelente e apresentou valor entre 0.9 e 1 [77], e pode-se observar que melhorou consideravelmente em relação aos outros três experimentos. Apesar da arquitetura proposta ter apresentado o melhor resultado no experimento do *UBIRISv2*, não foi tão superior quanto aos calculados nos outros três experimentos e a *AUC* calculada foi pobre [77], apresentando valores entre 0.6 e 0.7.

Portanto, pelas *AUC* calculados, pode-se afirmar que com pelo menos uma métrica de qualidade, o desempenho de sistemas de reconhecimento de íris é melhorado, onde em um banco de imagens usando somente a métrica de qualidade *DSMI* obteve o melhor resultado e nos outros três bancos de imagens a arquitetura proposta obteve os melhores resultados, em especial nos bancos de imagens *UBIRISv1* e *Warsaw*, em que a arquitetura melhorou consideravelmente o desempenho de sistemas de reconhecimento de íris.

5.3.2 Taxa de Erro Igual (*EER*)

EER é uma métrica utilizada para calcular o desempenho de sistemas biométricos [79]. É calculada, assim como *AUC*, com base nas taxas *TPR*, *TNR*, *FPR* e *FNR* resultantes do processo de decisão do sistema. A taxa *EER* consiste no ponto em que as taxas de erro *FPR* e *FNR* são iguais, conforme as Equações 5.1 e 5.2 [76]:

$$EER = FPR(T_*) = FNR(T_*), \quad (5.1)$$

onde

$$T_* = \underset{T}{\operatorname{argmin}}(|FPR(T) - FNR(T)|) \quad (5.2)$$

é o limiar de decisão que melhor aproxima a igualdade da Equação 5.1. Quanto mais próximo de 0 for a *EER* calculada, melhor o desempenho do sistema [76]. Na Tabela 5.5, os *EER* calculados para todos os experimentos são apresentados.

Tabela 5.5: Valores calculados para *EER* dos bancos de imagens.

	<i>MICHE</i>	<i>UBIRISv1</i>	<i>UBIRISv2</i>	<i>Warsaw</i>
SM	0.379	0.388	0.416	0.180
DSMI	0.370	0.327	0.408	0.095
FCE	0.394	0.355	0.407	0.105
DM	0.392	0.097	0.394	0.023

A melhor *EER* calculada para o banco de imagens *MICHE* foi usando somente a métrica de qualidade *DSMI*. O valor calculado, assim como aquele encontrado para *AUC*,

são valores regulares, porque quanto maior a *EER*, pior o desempenho do sistema [79, 76] e reafirmam a dificuldade do *MICHE*.

Assim como no experimento da *AUC*, a melhor *EER* do banco de imagens *Warsaw* foi calculada usando a arquitetura proposta. Os valores também são excelentes, porque são próximos de 0 [79, 76].

A arquitetura proposta, assim como na métrica *AUC*, apresentou os melhores resultados nos bancos de imagens *UBIRISv1* e *UBIRISv2*. E assim como os resultados de *AUC*, o valor apresentado no *UBIRISv2* é considerado fraco, porque é uma *EER* elevada e no *UBIRISv1* é excelente, com valor perto de 0 [79, 76].

A arquitetura proposta obteve os melhores resultados em três dos quatro bancos de imagens e usando a métrica de qualidade *DSMI* no outro, onde nos bancos de imagens *UBIRISv1* e *Warsaw* a arquitetura melhorou o rendimento consideravelmente em relação aos outros experimentos. Pode-se afirmar pelos resultados das *EER*, portanto, que utilizar pelo menos uma métrica de qualidade influencia no desempenho de sistemas de reconhecimento de íris.

5.3.3 Índice de Daugman (d')

O limiar de decisão do sistema biométrico que influencia nas taxa de acerto e erro nas correspondências. Quanto mais conservador, maior a *FNR* e quanto menos criterioso, maior a *FPR* [78]. As sobreposições das distribuições das Distância Hamming de correspondências aceitas e rejeitadas quantificam o poder de decisão do sistema, e essas sobreposições consistem nas taxas *FPR* e *FNR*. A métrica d' foi proposta de forma a calcular a separação da distribuição das íris aceitas e rejeitadas, o grau de detrimento entre as duas taxas de erro e quantificar em um valor a capacidade de decisão de um sistema de reconhecimento de íris, e é descrita pela Equação 5.3 [78]:

$$d' = \frac{|\mu_1 - \mu_2|}{\sqrt{\frac{1}{2}(\sigma_1^2 + \sigma_2^2)}}, \quad (5.3)$$

onde μ_1 e μ_2 são as médias das *Distância Hamming* das íris que foram aceitas e rejeitadas, respectivamente, enquanto σ_1^2 e σ_2^2 são seus desvios padrões. Quanto maior o valor de d' , melhor o poder de decisão do sistema de reconhecimento de íris.

Nos experimentos realizados, d' foi calculado utilizando quatro limiares de decisão: $T_1 = 0.2$, $T_2 = 0.3$, $T_3 = 0.4$ e T_{EER} . T_{EER} consiste nos limiares encontrados no ponto da *EER*.

Nos experimentos, os valores do d' calculados apresentaram os melhores resultados com os menores limiares. Isso pode ser explicado porque quanto menor o limiar, menor a média dos valores da *HD* das comparações aceitas, e como a média das *HD* das comparações

Tabela 5.6: Valores calculados para d' nos experimentos.

	<i>MICHE</i>				<i>UBIRISv1</i>				<i>UBIRISv2</i>				<i>Warsaw</i>			
	T_1	T_2	T_3	T_{EER}	T_1	T_2	T_3	T_{EER}	T_1	T_2	T_3	T_{EER}	T_1	T_2	T_3	T_{EER}
SM	5.70	3.48	2.13	1.94	6.57	3.86	2.29	1.92	3.99	2.67	1.68	1.48	7.38	4.70	1.88	1.42
DSMI	6.10	3.86	2.34	2.17	6.74	4.16	2.21	1.86	4.09	2.67	1.62	1.41	7.62	4.82	2.06	1.56
FCE	7.24	4.13	1.91	1.82	8.33	5.06	1.72	1.45	8.10	3.96	2.39	2.26	8.43	5.16	2.26	1.31
DM	6.51	4.10	2.37	2.18	9.42	6.49	1.74	1.55	7.29	3.86	2.61	2.42	7.82	5.04	2.44	1.95

rejeitadas mantêm-se praticamente constante, o numerador da Equação 5.3 aumenta e os seus resultados conseqüentemente.

O banco de imagens *MICHE* apresentou os maiores índices com a arquitetura proposta com os limiares T_3 e T_{EER} . No *UBIRISv1*, os dois maiores valores com a arquitetura proposta foram calculados com dois limiares: T_1 e T_2 . O banco de imagens *UBIRISv2* também apresentou dois maiores valores com a arquitetura proposta com os limiares T_2 e T_3 . Os resultados encontrados com a arquitetura proposta no *Warsaw* apresentou os maiores valores em dois limiares no índice: T_3 e T_{EER} . O único banco de imagens que apresentou valores maiores sem nenhuma métrica de qualidade, foi o *UBIRISv1*, com os limiares T_3 e T_{EER} , e pode ser explicado porque apesar da diferença absoluta das médias ter sido pequena, as suas variâncias calculadas foram menores que as usando métricas de qualidade, de forma que os valores do d' foram maiores.

Os resultados encontrados na arquitetura proposta usando o índice de desempenho d' apresentaram os melhores valores em metade dos experimentos gerais. Os valores menores podem ser explicados pela variância da *HD* calculada para as correspondências aceitas com a arquitetura proposta. Como a quantidade de imagens filtradas pelas duas métricas é menor, a sua variância aumenta e quanto maior a variância, com as médias mantendo valores parecidos, maior o denominador da Equação 5.3 e menor o valor do índice calculado.

Os maiores índices globais para cada banco de imagens foram calculados utilizando pelo menos uma métrica de qualidade, onde a arquitetura proposta se não obteve o maior índice, esteve entre os dois maiores. Esses dados afirmam que métricas de qualidade melhoram a taxa de decisão de sistemas de reconhecimento de íris.

No próximo capítulo, as conclusões quanto ao projeto e a arquitetura proposta com as duas métricas de qualidade são apresentadas.

Capítulo 6

Conclusão

Neste projeto, foi proposto uma arquitetura de sistema de reconhecimento de íris *LV* flexível para qualquer algoritmo de segmentação, codificação e correspondência de íris, que utiliza duas métricas de qualidade: uma para avaliar a qualidade de imagens de íris chamada *DSMI* e outra para avaliar a qualidade da etapa de segmentação de íris chamada *FCE*.

Foi sugerido no projeto que a utilização de duas métricas de qualidade, diferentemente de usar métricas de qualidade somente antes ou depois da segmentação, melhoraria o desempenho de sistemas de reconhecimento de íris. Para realizar os experimentos, foram utilizados quatro bancos de imagens de íris *LV*: *MICHE*, *UBIRISv1*, *UBIRISv2* e *Warsaw-BioBase-Smartphone-Iris-v1.0 (Warsaw)*.

Foram realizados quatro experimentos utilizando os índices de desempenho *AUC* e *ROC*, *EER* e d' . Os resultados variaram para cada banco de dados, onde no *UBIRISv1* e *Warsaw* a arquitetura proposta melhorou substancialmente o desempenho de sistemas de reconhecimento de íris nos índices de desempenho *AUC* e *EER*. Já no índice de desempenho d' , os resultados obtidos para cada banco de dados dependeram do limiar empregado. Portanto, utilizar duas métricas de qualidade podem melhorar o desempenho de sistemas de reconhecimento de íris *LV*. No entanto, estudos mais aprofundados devem ser feitos de forma a generalizar os melhores desempenhos, sem depender do banco de imagens.

Foi observado que a etapa de segmentação foi um dos fatores para essas diferenças de resultados, porque enquanto nos bancos de dados *UBIRISv1* e *Warsaw* o algoritmo de segmentação do sistema de reconhecimento de íris *OSIRISv4.1* conseguiu segmentar corretamente as íris, nos bancos *MICHE* e *UBIRISv2*, as íris, em sua maioria, foram incorretamente segmentadas, por conta do desafio de segmentar as imagens desses bancos e de limitações do *OSIRISv4.1*. Portanto, outros sistemas de reconhecimento de íris com diferentes algoritmos de segmentação podem ser usados para testar a arquitetura proposta.

Apesar do projeto proposto ter consistido em utilizar as métricas de qualidade *DSMI* e

FCE, a arquitetura proposta é flexível para outras métricas de qualidade de imagens de íris e da etapa de segmentação. Portanto, outras métricas de qualidade podem ser aplicadas ou até combinadas com aquelas já utilizadas no sistema para avaliar o desempenho de sistemas de reconhecimento de íris.

Referências

- [1] Trokielewicz, Mateusz: *Iris recognition with a database of iris images obtained in visible light using smartphone camera*. fevereiro 2016. ix, 1, 3, 18, 19, 39, 43
- [2] Wayman, J.L., A.K. Jain, D. Maltoni e D. Maio: *Biometric Systems: Technology, Design and Performance Evaluation*. Springer London, 2005, ISBN 9781846280641. <https://books.google.com.br/books?id=LkHHDZtQwG0C>. 1, 4, 5, 6, 7, 8, 9, 17, 19, 50
- [3] Li, S.Z. e A.K. Jain: *Encyclopedia of Biometrics*. Número v. 2 em 2009 Springer E-Books. Springer, 2009, ISBN 9780387730028. <https://books.google.com.br/books?id=0bQb0YVULQcC>. 1, 4, 7
- [4] Daugman, J.: *How Iris Recognition Works*. IEEE Transactions on Circuits and Systems for Video Technology, 14(1):21–30, 2004. 1, 2, 17, 19, 20, 21, 22, 24, 37
- [5] *Verieye sdk - iris identification for stand-alone and web solutions*. <https://www.neurotechnology.com/verieye.html>. Acessado: 2019-06-03. 1, 8
- [6] Othman, Nadia, Bernadette Dorizzi e Sonia Garcia-Salicetti: *Osiris: An open source iris recognition software*. Pattern Recognition Letters, 82, setembro 2015. 1, 3, 31
- [7] Proenca, H.: *Quality assessment of degraded iris images acquired in the visible wavelength*. IEEE Transactions on Information Forensics and Security, 6(1):82–95, March 2011, ISSN 1556-6013. 1, 2, 25
- [8] Raja, K. B., R. Raghavendra e C. Busch: *Binarized statistical features for improved iris and periocular recognition in visible spectrum*. Em *2nd International Workshop on Biometrics and Forensics*, páginas 1–6, March 2014. 1
- [9] Raja, Kiran B., Ramachandra Raghavendra, Vinay Krishna Vemuri e Christoph Busch: *Smartphone based visible iris recognition using deep sparse filtering*. Pattern Recognition Letters, 57:33–42, 2015. 1
- [10] Abdullah, M. A. M., J. A. Chambers, W. L. Woo e S. S. Dlay: *Iris biometric: Is the near-infrared spectrum always the best?* Em *2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR)*, páginas 816–819, Nov 2015. 1, 19
- [11] Starovoitov, Valery, Agnieszka Kitlas Golińska, Anna Predko-Maliszewska e Maciej Goliński: *No-reference image quality assessment for iris biometrics*. Em *Advances in Intelligent Systems and Computing*, páginas 95–100. Springer Berlin Heidelberg, 2013. https://doi.org/10.1007/978-3-642-32384-3_12. 2, 24

- [12] Jenadeleh, Mohsen, Marius Pedersen e Dietmar Saupe: *Realtime quality assessment of iris biometrics under visible light*. Em *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, June 2018. 2, 23, 24, 25, 26, 27, 45
- [13] Wan, Jing, Xiaofu He e Pengfei Shi: *An iris image quality assessment method based on laplacian of gaussian operation*, 2007. 2, 24
- [14] Bergmüller, Thomas, Eleftherios Christopoulos, Kevin Fehrenbach, Martin Schnöll e Andreas Uhl: *Recompression effects in iris recognition*. *Image and Vision Computing*, 58:142–157, fevereiro 2017. <https://doi.org/10.1016/j.imavis.2016.08.003>. 2, 24
- [15] Chen, L., M. Han e H. Wan: *The fast iris image clarity evaluation based on brenner*. Em *2013 2nd International Symposium on Instrumentation and Measurement, Sensor Network and Automation (IMSNA)*, páginas 300–302, Dec 2013. 2, 24
- [16] Kalka, N. D., J. Zuo, N. A. Schmid e B. Cukic: *Estimating and fusing quality factors for iris biometric images*. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 40(3):509–524, May 2010, ISSN 1083-4427. 2, 24
- [17] Li, X., Z. Sun e T. Tan: *Comprehensive assessment of iris image quality*. Em *2011 18th IEEE International Conference on Image Processing*, páginas 3117–3120, Sep. 2011. 2, 24
- [18] Du, Yingzi, Craig Belcher, Zhi Zhou e Robert Ives: *Feature correlation evaluation approach for iris feature quality measure*. *Signal Processing*, 90:1176–1187, abril 2010. 2, 23, 25, 27, 28, 29, 36, 45
- [19] Belcher, C. e Y. Du: *A selective feature information approach for iris image-quality measure*. *IEEE Transactions on Information Forensics and Security*, 3(3):572–577, Sep. 2008, ISSN 1556-6013. 2, 24, 25, 28
- [20] Mottalli, M., M. Mejail e J. Jacobo-Berlles: *Flexible image segmentation and quality assessment for real-time iris recognition*. Em *2009 16th IEEE International Conference on Image Processing (ICIP)*, páginas 1941–1944, Nov 2009. 2, 25
- [21] Li Ma, Tieniu Tan, Yunhong Wang e Dexin Zhang: *Personal identification based on iris texture analysis*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(12):1519–1533, Dec 2003, ISSN 0162-8828. 2, 25
- [22] De Marsico, Maria, Michele Nappi, Fabio Narducci e Hugo Proença: *Insights into the results of miche i - mobile iris challenge evaluation*. *Pattern Recognition*, 74, setembro 2017. 3, 39
- [23] Proença, H. e L.A. Alexandre: *UBIRIS: A noisy iris image database*. Em *13th International Conference on Image Analysis and Processing - ICIAP 2005*, volume LNCS 3617, páginas 970–977, Cagliari, Italy, September 2005. Springer. 3, 39, 41
- [24] Proença, H., S. Filipe, R. Santos, J. Oliveira e L.A. Alexandre: *The UBIRIS.v2: A database of visible wavelength images captured on-the-move and at-a-distance*. *IEEE Trans. PAMI*, 32(8):1529–1535, August 2010. 3, 39, 42

- [25] WAYMAN, JAMES L.: *FUNDAMENTALS OF BIOMETRIC AUTHENTICATION TECHNOLOGIES*. International Journal of Image and Graphics, 01(01):93–113, janeiro 2001. <https://doi.org/10.1142/s0219467801000086>. 5
- [26] Zhou, Z., E. Y. Du, C. Belcher, N. L. Thomas e E. J. Delp: *Quality fusion based multimodal eye recognition*. Em *2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, páginas 1297–1302, Oct 2012. 6, 27
- [27] Jagadiswary, D. e D. Saraswady: *Biometric authentication using fused multimodal biometric*. Procedia Computer Science, 85:109–116, 2016. <https://doi.org/10.1016/j.procs.2016.05.187>. 6
- [28] *Futronic fs80h*. <https://www.biometricssupply.com/product/futronic-fs80h/>. Acessado: 2019-06-03. 7
- [29] *Lg irisaccess 4000 system*. <https://www.domesticpreparedness.com/updates/lg-irisaccess-4000-system/>. Acessado: 2019-06-03. 7
- [30] *Fingerprint services*. <https://www.tualatinoregon.gov/police/fingerprint-services>. Acessado: 2019-06-03. 8
- [31] Gonzalez, Rafael C. e Richard E. Woods: *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2006, ISBN 013168728X. 9, 12, 13, 14, 15, 16, 18, 19
- [32] Ojala, T., M. Pietikainen e T. Maenpaa: *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 24(7):971–987, July 2002, ISSN 0162-8828. 10
- [33] Guo, Z., L. Zhang e D. Zhang: *A completed modeling of local binary pattern operator for texture classification*. IEEE Transactions on Image Processing, 19(6):1657–1663, June 2010, ISSN 1057-7149. 10, 25
- [34] *Local standard deviation of image*. <https://www.mathworks.com/help/images/ref/stdfilt.html>. Acessado: 2019-05-28. 11
- [35] Otsu, N.: *A Threshold Selection Method from Gray-Level Histograms*. IEEE Transactions on Systems, Man, and Cybernetics, 9(1):62–66, 1979. 12
- [36] *Eroding and dilating*. https://docs.opencv.org/2.4/doc/tutorials/imgproc/erosion_dilatation/erosion_dilatation.html. Acessado: 2019-05-27. 13, 15
- [37] Kovesi, Peter: *Log-gabor filters*. <https://www.peterkovesi.com/matlabfns/PhaseCongruency/Docs/convexpl.html>. Acessado: 2019-05-29. 15, 16
- [38] Oppenheim, A.V. e A.S. Willsky: *Signals and Systems: Pearson New International Edition*. Always learning. Pearson Education Limited, 2013, ISBN 9781292025902. <https://books.google.com.br/books?id=ut9oAQAACAAJ>. 15
- [39] Field, David J.: *Relations between the statistics of natural images and the response properties of cortical cells*. J. Opt. Soc. Am. A, 4(12):2379–2394, Dec 1987. <http://josaa.osa.org/abstract.cfm?URI=josaa-4-12-2379>. 16

- [40] Masek, Libor: *Recognition of human iris patterns for biometric identification*. Relatório Técnico, 2003. 16, 20
- [41] *Advantages and disadvantages of the iris for identification*. <https://www.cl.cam.ac.uk/~jgd1000/addisadvans.html>. Acessado: 2019-06-04. 17
- [42] *Anatomy and physiology of the iris*. <https://www.cl.cam.ac.uk/~jgd1000/anatomy.html>. Acessado: 2019-05-24. 17
- [43] Kaufman, P.L., A. Alm e F.H. Adler: *Adler's Physiology of the Eye: Clinical Application*. Adler's Physiology of the Eye. Mosby, 2003, ISBN 9780323011365. <https://books.google.com.br/books?id=2YlsAAAAMAAJ>. 17
- [44] *Como funciona o olho humano?* <http://hob.med.br/como-funciona-o-olho-humano/>. Acessado: 2019-05-23. 18
- [45] *Biometria - reconhecimento de Íris*. https://www.gta.ufrj.br/grad/08_1/iris/index.html. Acessado: 2019-05-23. 17
- [46] *The electromagnetic spectrum*. https://www.miniphysics.com/electromagnetic-spectrum_25.html. Acessado: 2019-05-26. 18
- [47] *Near infrared images*. <http://www.paulillsley.com/infrared/index.html>. Acessado: 2019-05-26. 19
- [48] *Some examples of iris images acquired in infrared light (700 nm - 850 nm)*. https://www.miniphysics.com/electromagnetic-spectrum_25.html. Acessado: 2019-06-04. 19
- [49] *Daugman's rubber sheet model*. https://www.researchgate.net/figure/Daugmans-Rubber-Sheet-Model_fig2_257380608. Acessado: 2019-06-04. 20
- [50] Daugman, J.: *Probing the uniqueness and randomness of iriscodes: Results from 200 billion iris pair comparisons*. Proceedings of the IEEE, 94(11):1927–1935, Nov 2006, ISSN 0018-9219. 20
- [51] *Iriscode*. <https://www.cl.cam.ac.uk/~jgd1000/iriscode.jpg>. Acessado: 2019-06-04. 22
- [52] Zhang, L., L. Zhang e A. C. Bovik: *A feature-enriched completely blind image quality evaluator*. IEEE Transactions on Image Processing, 24(8):2579–2591, Aug 2015, ISSN 1057-7149. 23, 24
- [53] Xu, Shaoping, Shunliang Jiang e Weidong Min: *No-reference/blind image quality assessment: A survey*. IETE Technical Review, 34(3):223–245, abril 2016. <https://doi.org/10.1080/02564602.2016.1151385>. 23
- [54] Moorthy, A. K. e A. C. Bovik: *A two-step framework for constructing blind image quality indices*. IEEE Signal Processing Letters, 17(5):513–516, May 2010, ISSN 1070-9908. 23

- [55] Liu, Lixiong, Bao Liu, Hua Huang e Alan Bovik: *No-reference image quality assessment based on spatial and spectral entropies*. Signal Processing Image Communication, 29, setembro 2014. 23
- [56] Jenadeleh, Mohsen e Mohsen Ebrahimi Moghaddam: *Biqws: efficient wakeby modeling of natural scene statistics for blind image quality assessment*. Multimedia Tools and Applications, 76, julho 2016. 23
- [57] Jenadeleh, Mohsen, Mohammad Masood Masaeli e Mohsen Ebrahimi Moghaddam: *Blind image quality assessment based on aesthetic and statistical quality-aware features*. Journal of Electronic Imaging, 26:1, agosto 2017. 23
- [58] El-Abed, Mohamad, Christophe Charrier e Christophe Rosenberger: *Quality Assessment of Image-based Biometric Information*. EURASIP Journal on Image and Video Processing, página 0, fevereiro 2015. <https://hal.archives-ouvertes.fr/hal-01101548>. 24
- [59] Lowe, David G.: *Distinctive image features from scale-invariant keypoints*. International Journal of Computer Vision, 60(2):91–110, novembro 2004. <https://doi.org/10.1023/b:visi.0000029664.99615.94>. 24
- [60] Sharma, Ram Prakash e Somnath Dey: *Fingerprint image quality assessment and scoring*. Em *Mining Intelligence and Knowledge Exploration*, páginas 156–167. Springer International Publishing, 2017. https://doi.org/10.1007/978-3-319-71928-3_16. 24
- [61] Wasnik, P., K. B. Raja, R. Ramachandra e C. Busch: *Assessing face image quality for smartphone based face recognition system*. Em *2017 5th International Workshop on Biometrics and Forensics (IWBF)*, páginas 1–6, April 2017. 24
- [62] MacKay, David J. C.: *Information Theory, Inference & Learning Algorithms*. Cambridge University Press, New York, NY, USA, 2002, ISBN 0521642981. 28
- [63] *Iris_osiris*. https://github.com/5455945/Iris_Osiris. Acessado: 2019-06-14. 31, 36, 38
- [64] *A biometric reference system for iris osiris version 4.1*. https://github.com/5455945/Iris_Osiris/blob/master/doc/Documentation_OSIRIS_v4.1.pdf. Acessado: 2019-06-14. 31, 34, 36, 37, 38
- [65] Kanopoulos, N., N. Vasanthavada e R. L. Baker: *Design of an image edge detection filter using the sobel operator*. IEEE Journal of Solid-State Circuits, 23(2):358–367, April 1988, ISSN 0018-9200. 34
- [66] Sutra, G., S. Garcia-Salicetti e B. Dorizzi: *The viterbi algorithm at different resolutions for enhanced iris segmentation*. Em *2012 5th IAPR International Conference on Biometrics (ICB)*, páginas 310–316, March 2012. 34

- [67] Castrillón-Santana, M., M. De Marsico, M. Nappi, F. Narducci e H. Proença: *Mobile iris challenge evaluation ii: Results from the icpr competition*. Em *2016 23rd International Conference on Pattern Recognition (ICPR)*, páginas 149–154, Dec 2016. 39, 40
- [68] *Miche-i dataset*. <http://biplab.unisa.it/MICHE/>. Acessado: 2019-06-19. 39
- [69] *Ubiris.v1*. <http://iris.di.ubi.pt/ubiris1.html>. Acessado: 2019-06-19. 39, 41
- [70] *Ubiris.v2*. <http://iris.di.ubi.pt/ubiris2.html>. Acessado: 2019-06-19. 39
- [71] *Biometric databases*. <http://zbum.ia.pw.edu.pl/EN/node/46>. Acessado: 2019-06-19. 39
- [72] *Open source computer vision library*. <https://opencv.org/>. Acessado: 2019-05-27. 49
- [73] *Numpy*. <http://www.numpy.org/>. Acessado: 2019-06-19. 49
- [74] *scikit-learn*. <https://scikit-learn.org/stable/>. Acessado: 2019-06-19. 49
- [75] *Matplotlib*. <https://matplotlib.org/>. Acessado: 2019-06-19. 49
- [76] Poh, N., C H. Chan, J. Kittler, Julian Fierrez e Javier Galbally: *D3.3: Description of metrics for the evaluation of biometric performance*. 2012. 50, 52, 53
- [77] *The area under an roc curve*. <http://gim.unmc.edu/dxtests/roc3.htm>. Acessado: 2019-06-20. 50, 51, 52
- [78] Daugman, John: *Biometric decision landscapes*. IEEE Transactions on Reliability - TR, janeiro 2000. 50, 53
- [79] *Understanding biometric performance evaluation*. <https://precisebiometrics.com/wp-content/uploads/2014/11/White-Paper-Understanding-Biometric-Performance-Evaluation.pdf>. Acessado: 2019-06-20. 50, 52, 53