

**UNIVERSIDADE FEDERAL DA PARAÍBA**  
**CENTRO DE INFORMÁTICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**

**NOVO ALGORITMO DE SEGMENTAÇÃO E REALCE DE**  
**IMAGENS DE IMPRESSÕES DIGITAIS**

**RAMON CELESTINO RAMOS**

**JOÃO PESSOA - PB**

**Maio - 2018**

**UNIVERSIDADE FEDERAL DA PARAÍBA**  
**CENTRO DE INFORMÁTICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**

**NOVO ALGORITMO DE SEGMENTAÇÃO E REALCE DE**  
**IMAGENS DE IMPRESSÕES DIGITAIS**

**RAMON CELESTINO RAMOS**

Dissertação submetida ao Centro de Informática da Universidade Federal da Paraíba como parte dos requisitos necessários para obtenção do grau de Mestre em Informática.

Orientador: Prof. Dr. Leonardo Vidal Batista

**João Pessoa**

**2018**

R175n Ramos, Ramon Celestino.

Novo algoritmo de segmentação e realce de imagens de impressões digitais / Ramon Celestino Ramos. - João Pessoa, 2018.

102 f. : il.

Orientação: Leonardo Vidal Batista.

Dissertação (Mestrado) - UFPB/CI.

1. Informática. 2. Biometria - Impressão Digital. 3. Técnicas de segmentação e realce. 4. Extração de Características. I. Batista, Leonardo Vidal. II. Título.

UFPB/BC



UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA



Ata da Sessão Pública de Defesa de Dissertação de Mestrado de Ramon Celestino Ramos, candidato ao título de Mestre em Informática na Área de Sistemas de Computação, realizada em 25 de maio de 2018.

Aos vinte e cinco dias do mês de maio, do ano de dois mil e dezoito, às dez horas, no Centro de Informática da Universidade Federal da Paraíba, em Mangabeira, reuniram-se os membros da Banca Examinadora constituída para julgar o Trabalho Final do Sr. Ramon Celestino Ramos, vinculado a esta Universidade sob a matrícula nº 20161005625, candidato ao grau de Mestre em Informática, na área de "Sistemas de Computação", na linha de pesquisa "Sinais, Sistemas Digitais e Gráficos", do Programa de Pós-Graduação em Informática, da Universidade Federal da Paraíba. A comissão examinadora foi composta pelos professores: Leonardo Vidal Batista (PPGI-UFPB), Orientador e Presidente da Banca, Thais Gaudêncio do Rego (PPGI-UFPB), Examinador interno, Suzete Élide Nóbrega Correia (IFPB), examinador externo à Instituição. Dando início aos trabalhos, o Presidente da Banca, cumprimentou os presentes, comunicou aos mesmos a finalidade da reunião e passou a palavra ao candidato para que o mesmo fizesse a exposição oral do trabalho de dissertação intitulado "Novo Algoritmo de Segmentação e Realce de Imagens de Impressões Digitais". Concluída a exposição, o candidato foi arguido pela Banca Examinadora que emitiu o seguinte parecer: "**aprovado**". Do ocorrido, eu, Clauriton de Albuquerque Siebra, Coordenador do Programa de Pós-Graduação em Informática, lavrei a presente ata que vai assinada por mim e pelos membros da banca examinadora. João Pessoa, 25 de maio de 2018.

Prof. Dr. Clauriton de Albuquerque Siebra

*Clauriton de Albuquerque Siebra*  
Coordenador do Programa de  
Pós-Graduação em Informática  
SIAPE 1723481

Prof. Dr. Leonardo Vidal Batista  
Orientador (PPGI-UFPB)

Prof. Dr. Thais Gaudêncio do Rego  
Examinadora interna (PPGI-UFPB)

Prof. Dr. Suzete Élide Nóbrega Correia  
Examinadora externa (IFPB)

*Dedico esta conquista à minha amada mãe Viviane Celestino.*

## **Agradecimentos**

À minha família. À minha mãe, Viviane Celestino, por me dar todo o apoio e incentivo desde a minha infância, por acreditar e confiar em mim, por contribuir tanto para a minha formação acadêmica quanto para a formação do meu caráter. Por demonstrar seu carinho e cuidado todos os dias, sempre buscando o melhor para mim e para meu irmão. Agradeço por tudo, por cada momento, e qualquer palavra aqui escrita não seria suficiente para demonstrar o amor e admiração que tenho por ela. Ao meu pai, Walber Farias, por me dar muito mais que apoio financeiro, demonstrando seu amor e preocupação com a minha vida e meu futuro. Ao meu irmão, Gabriel Celestino, por sempre confiar em mim e ser mais que um irmão, ser também um grande amigo que vou levar e cuidar para a vida toda.

À minha noiva, Thais Ruth Freire, por me acompanhar por tantos momentos, por me fazer ser melhor a cada dia. Por ser muito mais que minha noiva, sendo minha amiga e companheira para todas as horas. Por me incentivar a realizar meus sonhos e sonhar junto comigo. Por todas as conversas que tivemos e por me fazer seguir em frente.

Aos meus amigos da Vsoft, Iron Araújo, Rajiv Albino, Arthur, Igor Andrezza, Erick e Arnaldo por me acompanharem nessa caminhada e compartilharem o conhecimento, além do Sr. Pedro Alves, responsável pela empresa e por incentivar o desenvolvimento da pesquisa na Paraíba. Por me ajudarem a enfrentar diversos desafios.

À professora Dra. Thaís Gaudêncio do Rêgo, pelos conhecimentos passados durante a graduação e pós-graduação, além da prontidão para me ajudar nos momentos finais desta tese.

Ao meu orientador, professor Dr. Leonardo Vidal Batista e ao meu tutor Ms. João Janduy por acreditarem e confiarem na minha capacidade. Por passarem todo o conhecimento necessário para a realização deste trabalho e por me mostrarem o quão fascinante é a área de pesquisa.

## Resumo

A Biometria oferece um mecanismo de autenticação confiável utilizando traços (físicos ou comportamentais) que permitem identificar usuários baseados em suas características naturais. O reconhecimento por impressão digital é uma das abordagens biométricas mais utilizadas, visto que sua alta acurácia e seu baixo custo tornam os sistemas mais acessíveis e com resultados satisfatórios. Entretanto, ainda hoje, o reconhecimento por impressões digitais continua um problema em aberto, uma vez que erros de falsa aceitação e falsa rejeição ainda são encontrados nos algoritmos de comparação de impressões digitais. A presente pesquisa tem como objetivo o desenvolvimento de métodos para facilitar o processo de extração de características de impressões digitais, melhorando a qualidade da imagem de entrada através da utilização de novas técnicas de segmentação e realce, buscando reduzir as taxas de erro e alcançar resultados competitivos com algoritmos do estado-da-arte. As maiores contribuições deste trabalho foram a criação de dois métodos: segmentação da região de interesse das imagens de impressão digital, alcançando taxas de erro inferiores aos melhores algoritmos de segmentação do mundo em 10 de 12 bases de dados avaliadas, obtendo um ganho médio de 5,6% sobre o melhor algoritmo de segmentação da atualidade; criação do método de extração de características completo, baseado em trabalhos da literatura, realizando, contudo, correções e inovações em pontos chave para a obtenção de melhores resultados. O método de extração de características foi avaliado através da submissão do algoritmo para a competição de verificação de impressões digitais (*Fingerprint Verification Competition - FVC*), obtendo resultados promissores, sendo classificado como o segundo melhor algoritmo entre grupos de pesquisa e o único algoritmo de origem brasileira. Além disso, ao ser realizada a comparação com o algoritmo de realce base desse trabalho, o método desenvolvido nesta pesquisa obteve ganhos de 21% na acurácia.

**Palavras-chave:** Biometria, Impressão Digital, Realce, Segmentação, Extração de Características.

## **Abstract**

Biometrics provides a reliable authentication mechanism using physical or behavioral traits to identify users based on their natural characteristics. Fingerprint recognition is one of the most used biometrics approach, since its high accuracy and low cost make the system more affordable and acquire satisfactory results. However, fingerprint recognition is still an open problem, since false acceptance and false rejection errors are still found in matching algorithms. This research aims to create new methods in order to facilitate the feature extraction process, improving image quality through the use of inovative segmentation and enhancement techniques, seeking to reduce error rates and achieve competitive results among state-of-the-art algorithms. The main contributions of this work were the creation of the following methods: segmentation of the region of interest of fingerprint images, reaching error rates lower than the best segmentation algorithms in the world in 10 of 12 databases evaluated, obtaining an average gain of 5.6% over the best current segmentation algorithm; creation of the complete feature extraction method, based on state of art works, making corrections and innovations at key points to obtain better results. The feature extraction method was evaluated through the submission of the algorithm to the Fingerprint Verification Competition (FVC), obtaining promising results, being classified as the second best algorithm between research groups and the only algorithm of Brazilian origin. In addition, when the comparison with the base enhancement algorithm of this work was done, the method developed in this research obtained gains of 21% in accuracy.

**Keywords:** Biometrics, Fingerprint, Enhancement, Segmentation, Feature Extraction.

# Conteúdo

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Formulação do Problema . . . . .	3
1.2	Motivação . . . . .	5
1.3	Objetivos . . . . .	5
1.4	Estrutura da Dissertação . . . . .	6
<b>2</b>	<b>Conceitos Gerais e Revisão da Literatura</b>	<b>7</b>
2.1	Biometria . . . . .	7
2.2	Sistemas Biométricos . . . . .	9
2.3	Impressão Digital . . . . .	13
2.4	Extração de Características . . . . .	16
2.5	Padrão ISO de <i>templates</i> . . . . .	19
2.6	Matching . . . . .	21
2.7	Métricas de Erro . . . . .	22
2.8	Imagens e Processamento Digital de Imagens . . . . .	26
2.8.1	Binarização . . . . .	27
2.8.2	Mediana . . . . .	28
2.8.3	Segmentação . . . . .	29
2.9	Coefficiente de Similaridade de Jaccard . . . . .	29
2.10	Métrica de Comparação de Thai et al. . . . .	30
2.11	Filtros de Gabor . . . . .	31
2.12	Envoltório Convexo . . . . .	33

---

<b>3</b>	<b>Trabalhos Relacionados</b>	<b>34</b>
3.1	Trabalhos relacionados sobre o tema Enhancement . . . . .	34
3.2	Trabalhos relacionados sobre o tema ROI . . . . .	35
<b>4</b>	<b>Metodologia</b>	<b>39</b>
4.1	Ambiente de Desenvolvimento . . . . .	39
4.2	Método Proposto . . . . .	39
4.3	Segmentação da Região de Interesse . . . . .	40
4.3.1	Abordagem Proposta . . . . .	41
4.3.2	Validação do método de segmentação . . . . .	50
4.3.3	Seleção dos Parâmetros . . . . .	53
4.4	Realce da impressão digital ( <i>Enhancement</i> ) . . . . .	55
4.5	Afinamento, localização e filtragem de minúcias . . . . .	60
4.6	Métrica de Avaliação Geral . . . . .	62
4.7	Avaliação do tempo de processamento . . . . .	64
<b>5</b>	<b>Resultados e Discussões</b>	<b>66</b>
5.1	Resultados da avaliação dos métodos de segmentação de impressões digitais	66
5.2	Resultados da competição FVC . . . . .	70
5.3	Resultados obtidos pela métrica de avaliação geral . . . . .	73
5.4	Avaliação do tempo de processamento . . . . .	76
<b>6</b>	<b>Considerações finais e trabalhos futuros</b>	<b>78</b>
	<b>Bibliografia</b>	<b>85</b>

# Lista de Símbolos

**AFIS** : *Automated Fingerprint Identification System* (Sistema Automático de Identificação de Impressões Digitais)

**API** : *Application Programming Interface* (Interface de programação de aplicações)

**BMP** : *Windows Bitmap*

**DDR3** : *Double Data Rate 3*

**DPI** : *Dots Per Inch* (Pontos por Polegada)

**EER** : *Equal Error Rate* (Taxa de Erro Igual)

**FAR** : *False Acceptance Rate* (Taxa de Falsa Aceitação)

**FBI** : *Federal Bureau of Investigation* (Gabinete Federal de Investigação)

**FRR** : *False Rejection Rate* (Taxa de Falsa Rejeição)

**FVC** : *Fingerprint Verification Competition* (Competição de Verificação de Impressões Digitais)

**GAR** : *Genuine Accept Rate* (Taxa de Aceitação de Genuínos)

**GB** : *Giga Byte*

**IDE** : *Integrated Development Environment* (Ambiente Integrado de Desenvolvimento)

**NIST** : *National Institute of Standards and Technology* (Instituto Nacional de Padrões e Tecnologia)

**RAM** : *Random Access Memory* (Memória de Acesso Aleatório)

**ROC** : *Receiver Operator Characteristic Curve* (Curva de Característica de Operação do Receptor)

**ROI** : *Region of Interest* (Região de Interesse)

**SDK** : *Standard Development Kit* (Kit de Desenvolvimento de Software)

# Lista de Figuras

2.1	Etapas de sistemas Biométricos. Adaptado de (Costa, et al., 2006) . . . . .	11
2.2	Comparação de sistemas biométricos em relação à segurança e conveniência. Fonte: Kulp e Braskamp (2012) . . . . .	12
2.3	Comparação dos sistemas biométricos em relação ao custo e precisão. Fonte: Kulp e Braskamp (2012) . . . . .	12
2.4	Cristas e vales de uma impressão digital. Fonte: Maltoni, 2009 . . . . .	13
2.5	Regiões de singularidade (Caixas brancas) e pontos centrais (Círculos brancos) em impressões digitais. Fonte: Maltoni et al., 2009 . . . . .	14
2.6	Principais tipos de minúcias. Fonte: Maltoni et al., 2009 . . . . .	15
2.7	a) minúcia do tipo terminação: $[x_0, y_0]$ são as coordenadas da minúcia, $\theta$ é o ângulo que a tangente da minúcia forma com o eixo horizontal; b) minúcia do tipo bifurcação . . . . .	15
2.8	a) Parte de uma impressão digital, capturada a 1000 DPI, onde os poros ficam bem evidentes; b) Novas cristas; c) Vincos e cicatrizes . . . . .	16
2.9	Impressões digitais de qualidades diferentes . . . . .	18
2.10	Imagem de Impressão Digital com regiões de qualidades diferentes: a) região bem definida; b) região recuperável; c) região irrecuperável. . . . .	19
2.11	amostras deslocadas, rotacionadas e com ruído . . . . .	22
2.12	As curvas típicas das taxas de erro FAR e FRR, plotadas uma ao lado da outra, em relação ao limiar T configurado para o sistema. O sistema pode operar nas faixas de “conveniência” ou de “segurança”, conforme a calibração do limiar. Fonte: Costa, Obelheiro e Fraga (2006). . . . .	24
2.13	Exemplo matricial de imagem digital monocromática. Fonte: Batista, 2005. . . . .	26
2.14	Processamento digital de imagens e áreas correlatas. Fonte: Batista, 2005. . . . .	27

2.15	Exemplo de Binarização: (a) imagem original, (b) resultado da aplicação da binarização . . . . .	28
2.16	Exemplo de aplicação da mediana: (a) imagem original, (b) Resultado após a aplicação do filtro da mediana de tamanho 5x5 . . . . .	28
2.17	Segmentação de impressão digital . . . . .	29
2.18	Sobreposição de duas regiões de interesse de uma mesma impressão . . . . .	30
2.19	Representação gráfica (visão lateral e superior) do filtro de Gabor. Fonte: Maltoni et al., 2009. . . . .	31
2.20	Um conjunto de filtros de Gabor com seis orientações $\theta$ (colunas) e 3 frequências $f$ (linhas) Fonte: Maltoni et al., 2009. . . . .	32
2.21	Convolução com filtros de Gabor de diferentes orientações . . . . .	32
2.22	a) e c) Exemplos de pontos em um plano bidimensional contidos em um espaço definidos pela função envoltória convexa. b) Envoltória convexa em um espaço tridimensional. Fonte: (Weisstein, 2016) . . . . .	33
4.1	Fluxograma com todos os passos realizados no método de segmentação desenvolvido . . . . .	42
4.2	Exemplos de equalização de histograma sobre diferentes imagens de impressões digitais. (a) Impressão digital 27_8.bmp da base de dados FVC2002-1, (b) imagem de saída da impressão digital após a aplicação da operação de equalização de histograma, (c) Impressão digital 5_7.bmp da base de dados FVC2000-3, (d) imagem de saída da impressão digital 5_7.bmp após a aplicação da equalização de histograma. . . . .	44
4.3	Sinais de saída do filtro de Gabor utilizando frequências diferentes e $\sigma$ fixo	45
4.4	Sinal de saída do filtro de Gabor utilizando frequências diferentes e $\sigma$ definido dinamicamente de forma adaptativa. . . . .	45
4.5	Imagens Combinadas utilizando $\sigma$ fixo (a,c) e $\sigma$ definido dinamicamente de forma adaptativa (b,d) . . . . .	47

4.6	Todos os passos do método proposto. (a) Impressão digital de entrada, (b) operações com o histograma, (c) imagem combinada, (d) imagem de homogeneidade, (e) imagem filtrada, (f) binarização, (g) filtro de suavização, (h) maior região branca, (i) limpeza da imagem e (j) envoltório convexo. . . . .	49
4.7	Imagem de impressão digital segmentada de duas formas utilizando diferentes conceitos . . . . .	50
4.8	Diferença nos erros entre uma mesma imagem com apenas um recorte na região de <i>background</i> . (a) Imagem de entrada de impressão digital, (e) imagem de impressão digital recortada, (b,f) imagem gabarito segmentada manualmente, (c,g) método de segmentação proposto no presente trabalho, (d,h) imagem resultante da métrica de comparação de Thai, Huckemann e Gottschlich (2016). (A região branca é a região de interseção). . . . .	53
4.9	Etapas do processo de realce de imagens de impressões digitais realizado por Turrone, Cappelli e Maltoni (2012). . . . .	57
4.10	Evolução de uma imagem ruidosa de impressão digital durante o processo iterativo de <i>enhancement</i> . . . . .	58
4.11	Realce de impressões digitais através das diferentes abordagens de segmentação. . . . .	59
4.12	Binarização local . . . . .	60
4.13	Aplicação do filtro da mediana local . . . . .	61
4.14	Afinamento das cristas . . . . .	61
4.15	Remoção de falsas minúcias . . . . .	62
5.1	Diferentes taxas de erro entre as imagens segmentadas pelo algoritmo e a imagem segmentada manualmente, utilizando o filtro da maior região branca (8.22%) e utilizando todas as regiões com tamanhos maiores que um limiar (2.54%). . . . .	69
5.2	Amostras de impressões digitais de diferentes bases de dados: (a) Imagem 15_3 da base de dados FVC2000 DB3; (b) Imagem 3_8 da base de dados FVC2002 DB1; (c) Imagem 37_5 da base de dados FVC2006 DB2. . . . .	75

---

5.3 Comparação das frequências de cristas entre imagens de diferentes bases de dados: (a) Imagem 17\_4 da base FVC2004 DB1; (b) Imagem 15\_8 da base FVC2000 DB3 . . . . . 76

# Lista de Tabelas

2.1	Comparação dos traços biométricos mais utilizados. As percepções Alta, Média e Baixa são denotadas por A, M e B, respectivamente. Fonte: (Maltoni et al., 2009) . . . . .	8
2.2	Distribuição, por finalidade, das principais aplicações biométricas. Fonte: Mordini (2005) . . . . .	9
3.1	Principais algoritmos de segmentação e seus resultados obtidos através da comparação com segmentações manuais, como é o caso dos algoritmos testados através da métrica de avaliação de Thai et al. (2016) e comparações visuais. . . . .	38
4.1	Características das Bases de Dados . . . . .	51
4.2	Parâmetros utilizados no método proposto. . . . .	54
4.3	Visão geral sobre os valores dos parâmetros mais relevantes definidos no conjunto de treinamento. . . . .	55
4.4	Descrição dos bancos utilizados . . . . .	63
5.1	Comparação dos algoritmos utilizando o método de comparação proposto por Thai, Huckemann e Gottschlich (2016). Em negrito estão as menores taxas de erro por base de dados. . . . .	68
5.2	Taxas de erros obtidas pelo <i>BioPass Segmentation</i> , utilizando as duas técnicas de comparação citadas (Coeficiente de Jaccard e a métrica desenvolvida por Thai, Huckemann e Gottschlich (2016)). . . . .	70
5.3	Desempenho do método proposto, de cor verde, em relação aos demais candidatos em todas as versões do projeto FVC . . . . .	72

---

5.4	EER obtidos utilizando a extração dos algoritmos abaixo em conjunto com o algoritmo de casamento desenvolvido por Cappelli, Ferrara e Maltoni (2010)	74
5.5	Comparação do tempo de processamento para extração de características entre algoritmos . . . . .	77

# Capítulo 1

## Introdução

Os seres humanos utilizam traços físicos ou comportamentais, tais como face, voz e modo de caminhar, para reconhecer uns aos outros há milhares de anos. Com o passar do tempo surgiu a necessidade de utilizar esse reconhecimento de modo mais preciso e automatizado, principalmente devido a uma maior exigência de segurança em algumas áreas, tais como o reconhecimento de pessoas suspeitas em bancos, aeroportos e outros ambientes públicos onde terroristas e outros criminosos possam atuar, identificando-os a partir de traços que foram previamente gravados em bancos de dados (Marcialis et al., 2007).

A necessidade de se utilizar sistemas que pudessem identificar um indivíduo surgiu durante o século dezenove. Um dos maiores problemas para os departamentos de polícia dos grandes centros era identificar um criminoso reincidente e assim impor leis mais rígidas e penas mais duras para os mesmos. Muitos criminosos alteravam seus nomes que constavam nos registros dos departamentos de polícia para não serem classificados como reincidentes e assim, sendo esse o único registro, não era possível identificá-lo. Alphonse Bertillon, chefe da divisão criminal de identificação do departamento de polícia de Paris, desenvolveu e compartilhou a ideia de utilizar uma série de medidas do corpo para identificar os transgressores das leis (Jain et al., 2004). Em 1893, o departamento de segurança do Reino Unido, que é responsável pela imigração, lei e ordem do estado, assume que dois indivíduos não possuem a mesma impressão digital. Após essa descoberta, muitos dos principais departamentos de aplicação da lei perceberam o potencial das impressões digitais para os crimes reincidentes. Estes departamentos aderiram à ideia de catalogar as impressões digitais de criminosos no momento de sua prisão, assim seus registros estariam disponíveis em identificações futuras

---

(Maltoni et al., 2009).

Ao comparar manchas de impressões digitais em cenas dos crimes com as que foram catalogadas, as autoridades podiam determinar a identidade de criminosos que haviam sido presos anteriormente. As agências de segurança investiram em um estudo rigoroso das impressões digitais, desenvolvendo métodos científicos para a comparação visual das digitais e instituindo programas para treinamentos de especialistas na área (Maltoni et al., 2009).

À medida que a demanda por reconhecimento de impressões digitais crescia, dificuldades começaram a ser encontradas na utilização de métodos manuais, que mesmo com todas as tentativas de melhorias para aumentar a sua eficiência, não era suficiente para a quantidade de requisições que surgiam. O método manual de indexação da impressão digital (com base no sistema de classificação de Henry (1905)) resultou numa distribuição distorcida de tipos: muitas digitais eram classificadas em poucos tipos, o que não aumentava a eficiência da busca. Além disso, os procedimentos de treinamento eram intensivos e lentos, e a grande quantidade de impressões digitais necessitava de uma grande atenção para avaliá-las. O tédio do trabalho e o aumento na carga horária, decorrentes do aumento da demanda de serviços de reconhecimento das impressões digitais, levaram as agências de segurança a iniciarem pesquisas com o intuito de automatizar o processo de reconhecimento e indexação. Estes esforços levaram ao desenvolvimento de Sistemas de Identificação Automática de Impressões Digitais (*Automated Fingerprint Identification System - AFIS*) ao longo das últimas cinco décadas (Maltoni et al., 2009).

Embora a biometria tenha emergido pelo seu uso extensivo na aplicação da lei para identificar criminosos, atualmente está sendo cada vez mais usada para estabelecer reconhecimento de pessoas em um grande número de aplicações civis como determinação de paternidade, autorização de entrada em áreas de segurança, identificação durante eleições e certificado de segurança para funcionários (Jain et al., 2004). A drástica redução nos custos dos sistemas biométricos tornou a tecnologia viável para os negócios e não apenas para aplicações forenses.

Dessa forma, a biometria surgiu como uma alternativa para os métodos tradicionais na autenticação de indivíduos em diversos setores, seja em aplicações restritas, como sites, sistemas de votação, ou locais privados, como aeroportos e bancos. Os métodos tradicionais utilizados para estabelecer a identidade de um usuário incluem mecanismos baseados no

conhecimento (e.g., senhas) ou símbolos (e.g., cartões de identificação). No entanto, tais mecanismos podem ser perdidos, roubados ou até mesmo manipulados para enganar o sistema.

A autenticação biométrica por sua vez, não se baseia no conhecimento ou posse, mas em identificadores fisiológicos (impressões digitais, íris, face) e identificadores de procedimento (voz, assinatura) sendo considerada a princípio um método mais seguro, por exigir a apresentação de um traço físico único e, portanto, a presença do usuário ao menos no momento da autenticação.

No entanto, tais métodos também apresentam vulnerabilidades. Os serviços biométricos que utilizam a impressão digital como característica biométrica, por exemplo, podem permitir que uma reprodução da digital de um usuário em material de silicone seja usada para acesso indevido. A adoção de métodos para identificar o uso de dedos falsos (ausência de fluxo sanguíneo, perspiração, odor, etc) torna o processo complicado e custoso (Antonelli et al., 2006). O trabalho desenvolvido por Schuckers (2005) apontou 90% de taxa de verificação falsa em sistemas modernos de reconhecimento de digitais, utilizando-se dedos de cadáveres, de plástico, de gelatina e de outros materiais de modelagem (Roberts, 2007).

Dessa forma, para um traço biométrico ser considerado prático e poder ser utilizado em um sistema biométrico é preciso que o mesmo seja suficientemente robusto para possíveis ataques ao sistema e métodos fraudulentos, além de satisfazer os requisitos de reconhecimento de precisão, velocidade e recursos e não ser invasivo para os usuários (Jain et al., 2004).

## **1.1 Formulação do Problema**

O reconhecimento por impressão digital é uma das abordagens biométricas mais utilizadas, visto que sua alta acurácia e seu baixo custo tornam os sistemas mais acessíveis e com resultados satisfatórios. No entanto, atualmente, o reconhecimento por impressões digitais ainda é um problema em aberto, uma vez que erros de falsa aceitação e falsa rejeição ainda são encontrados nos algoritmos de comparação de impressões digitais. A confiabilidade desses algoritmos depende da qualidade da impressão digital de entrada. Se a qualidade é boa, a fluidez das linhas encontradas nas impressões digitais, conhecidas como cristas e vales

é bem evidente e um conjunto confiável de características pode ser extraída, caso contrário, quando a impressão possui muito ruído, o algoritmo pode detectar um grande número de falsas características e perder características verdadeiras (Turroni et al., 2012), resultando em taxas elevadas de falsa aceitação e rejeição.

Muitas vezes as imagens capturadas estão borradas, com ruídos, ou incompletas e precisam ser realçadas. Por isso, para obter uma imagem de entrada de qualidade é necessário realizar um realce (*enhancement*) na mesma. O realce de impressões digitais é a etapa de processamento da imagem que antecede a extração de minúcias e o reconhecimento da impressão digital, buscando destacar as cristas e vales e tornar a estrutura da impressão digital clara, reduzindo as falsas características.

Os principais métodos de realce de impressões digitais utilizam filtros de Gabor, tal como proposto por Hong et al. (1998). Filtros de Gabor têm ambas as propriedades de frequência e orientação seletiva e possuem resolução conjunta ideal em ambos os domínios espaciais e de frequência. Abordagens de realce de impressões digitais utilizando filtragem no domínio da frequência ou em uma mistura de domínio de frequência e domínio espacial têm sido propostas por vários autores: Chikkerur et al. (2007) e Jirachaweng e Areekul (2007), Sherlock et al. (1994). O método de realce apresentado por Turroni, Cappelli e Maltoni Turroni et al. (2012), mostra-se bastante eficaz. Seu método consiste em uma filtragem contextual com utilização de Gabor iterativo. No entanto, esse método possui algumas deficiências em relação a abordagem de aplicação do filtro de Gabor, além de possuir tempo de processamento demasiadamente demorado.

Atualmente, grande parte dos algoritmos de realce que utilizam filtros de Gabor, na literatura, apresentam erros em relação às imagens de baixa qualidade. Além disso, as melhores taxas de acerto em sistemas de reconhecimento automático de impressões digitais são de empresas privadas. O conhecimento nessa linha de pesquisa fica de certa forma presa em instituições privadas, já que as empresas não possuem interesse de publicar seus estudos.

Procurando analisar a importância da qualidade das impressões digitais para o resultado final de reconhecimento, este trabalho apresenta um novo algoritmo para segmentação e realce de impressões digitais, com o intuito de, posteriormente, realizar a extração de características, criação de *templates* e comparação.

## 1.2 **Motivação**

Com o crescimento da demanda por aplicações civis e governamentais que utilizam sistemas biométricos de impressão digital para identificação de indivíduos, a busca por sistemas mais rápidos e precisos vem gerando uma corrida entre empresas e comunidades acadêmicas pelo melhor algoritmo. Competições internacionais mostram que há uma grande vantagem das empresas privadas em relação ao meio acadêmico, principalmente nas etapas iniciais de processamento das imagens, que são cruciais para o processo completo de identificação, além disso, as pesquisas em âmbito nacional ainda são bastante escassas. Como se pode observar em BioLab (2006), uma competição de referência mundial que verifica o desempenho de algoritmos de identificação através de impressão digital, não existem algoritmos produzidos no Brasil. Isso implica em perda de espaço e de oportunidades neste país, quando se trata de mercado comercial público e privado, onde são priorizados produtos pesquisados e desenvolvidos em território nacional (Lei de Licitações, 8.666 de 1993; Instrução Normativa 04, 2010). Dessa forma, um algoritmo igualmente eficiente e de boa qualidade, como os produzidos em outros países, terá prioridade em licitações e no uso nacional em geral, como por exemplo: sistemas biométricos utilizados em votações eleitorais, fornecidos pelos Tribunais Eleitorais, que são sistemas que atuam em grande escala de uso.

Além disso, a literatura ainda apresenta trabalhos que são deficientes quando se trata de capturas de impressões digitais em casos especiais, como capturas de impressões digitais de baixa qualidade ou capturas de impressões digitais parciais.

O método de casamento de impressões digitais desenvolvido por Araujo (2015) representou um grande avanço para a pesquisa de impressões digitais no Brasil, obtendo resultados satisfatórios em competições internacionais. Assim, é possível utilizar o módulo de extração desenvolvido no presente trabalho em conjunto com o módulo de casamento desenvolvido por Araujo (2015) para criar um AFIS completo.

## 1.3 **Objetivos**

O objetivo geral desta dissertação é pesquisar e desenvolver algoritmos de segmentação, realce e melhoria de qualidade de imagens de impressões digitais, utilizando soluções ino-

vadoras em todas as etapas do processo, e que tenha taxas de erros semelhantes aos obtidos por instituições privadas. Os objetivos específicos são:

- Pesquisar e desenvolver métodos de realce de imagens de impressão digital.
- Realizar melhorias em algoritmos no estado da arte, como o desenvolvido por Turrone et al. (2012).
- Pesquisar e desenvolver algoritmos para delimitação da região de interesse de uma imagem de impressão digital, facilitando a atuação do método de realce e otimizando o processamento.
- Realizar análise comparativa entre o tempo de processamento, taxas de acertos, erros e desempenho do algoritmo desenvolvido com algoritmos da literatura em diferentes bases de dados reconhecidas internacionalmente.
- Avaliar as vantagens e desvantagens nos algoritmos para possíveis trabalhos futuros.
- Obter resultados competitivos em âmbito internacional na identificação de indivíduos por impressão digital.

## **1.4 Estrutura da Dissertação**

No Capítulo 2, será apresentada a fundamentação teórica necessária para o entendimento deste trabalho. Em seguida, no Capítulo 3, serão apresentados trabalhos relacionados presentes na literatura, tanto na parte de segmentação de impressões digitais, quanto na parte de realce e melhoria da qualidade. No capítulo 4, o método proposto será apresentado, juntamente com os métodos de avaliação que foram utilizados e os materiais da pesquisa. No Capítulo 5 serão apresentados os resultados e a discussão. E, por fim, no Capítulo 6 serão feitas as considerações finais deste trabalho.

## Capítulo 2

# Conceitos Gerais e Revisão da Literatura

Neste capítulo, são apresentados os principais conceitos teóricos empregados na realização deste trabalho, expondo os métodos existentes aplicados na validação do método proposto, conceitos gerais sobre Processamento Digital de Imagens e biometria.

### 2.1 Biometria

Diversas questões relacionadas com a identidade de um indivíduo são feitas diariamente em diferentes contextos. Essa pessoa está autorizada a entrar? Essa pessoa possui autorização para acessar informações privilegiadas? Essa pessoa é procurada por um crime? Essa pessoa já recebeu algum benefício? São necessárias respostas confiáveis para todas essas questões, uma vez que são necessárias para o mundo dos negócios e organizações governamentais. Devido ao fato de identificadores biométricos não serem facilmente confundidos, enganados, ou compartilhados, eles são considerados mais confiáveis para reconhecimento de pessoas do que os sistemas tradicionais de cartão, de identificação ou baseados em conhecimento, como as senhas. Conseqüentemente, Biometria não é somente um problema de pesquisa de reconhecimento de padrões, mas também uma tecnologia com potencial de tornar a sociedade mais segura, reduzir fraudes e prover comodidade ao usuário. O objetivo do reconhecimento biométrico é aumentar a conveniência para os usuários (como saques a Caixas ATM sem cartões ou senhas), melhorar a segurança, eficiência, entre outras vantagens.

O termo Biometria refere-se ao uso de traços físicos ou comportamentais para reconhecer e identificar indivíduos. Tais traços são os identificadores biométricos e podem abranger im-

pressões digitais, face, íris, voz, forma de escrever e etc. Conforme Clarke (1994), qualquer desses traços humanos pode ser usado como identificador biométrico desde que ele satisfaça alguns requisitos básicos:

- *Universalidade*: toda a população (a ser autenticada) deve possuir o traço.
- *Distinção*: indica o quanto um traço biométrico distingue um indivíduo do outro.
- *Permanência*: o traço biométrico deve ser imutável num longo intervalo de tempo.
- *Coleta*: o traço tem que ser passível de mensuração por meio de um dispositivo.
- *Desempenho*: indica a precisão, a velocidade e a robustez do sistema.
- *Aceitação*: a coleta do traço deve ser tolerada pelo indivíduo em questão.
- *Fraude*: indica a dificuldade de enganar o sistema.

É importante salientar que, na prática, nenhum traço biométrico atende com perfeição a todos os requisitos de um traço biométrico ideal (Clarke, 1994).

Pode-se observar através da Tabela 2.1 que o uso de impressões digitais apresenta diversas vantagens relacionadas às características desejadas de um sistema de identificação. Impressões digitais apresentam altos níveis de distinção, permanência e desempenho, além de facilidade e rapidez de aquisição através de sistemas digitais apropriados (escâneres).

Tabela 2.1: Comparação dos traços biométricos mais utilizados. As percepções Alta, Média e Baixa são denotadas por A, M e B, respectivamente. Fonte: (Maltoni et al., 2009)

<b>Identificador Biométrico</b>	<b>Universalidade</b>	<b>Distinção</b>	<b>Permanência</b>	<b>Coleta</b>	<b>Desempenho</b>	<b>Aceitação</b>	<b>Fraude</b>
Face	A	B	M	A	B	A	A
<b>Impressão Digital</b>	<b>M</b>	<b>A</b>	<b>A</b>	<b>M</b>	<b>A</b>	<b>M</b>	<b>M</b>
Geometria da Mão	M	M	M	A	M	M	M
Íris	A	A	A	M	A	B	B
Assinatura	B	B	B	A	B	A	A
Voz	M	B	B	M	B	A	A

Houve um considerável aumento no uso de reconhecimento por impressões digitais no âmbito comercial, governamental, civil e financeiro, ocasionado principalmente pelo sucesso da tecnologia em aplicações jurídicas, diminuição do custo de sensores para a captura de impressões digitais, o crescente aumento de poder computacional e o aumento das fraudes ideológicas, onde uma pessoa se passa por outra para obter seus benefícios (Maltoni et al., 2009). A Tabela 2.2 apresenta a distribuição das principais aplicações biométricas.

Tabela 2.2: Distribuição, por finalidade, das principais aplicações biométricas. Fonte: Mor-dini (2005)

<b>Finalidade</b>	<b>Utilização</b>
Identificação Criminal	28%
Controle de acesso e atendimento	22%
Identificação Civil	21%
Segurança de redes e de computadores	19%
Autenticação em pontos de vendas, ATM's e varejos	4%
Autenticação telefônica e comércio eletrônico	3%
Vigilância e filtragem	3%

No próximo tópico serão expostos os conceitos dos sistemas biométricos computacionais, detalhando as diferentes formas de reconhecimento e as etapas do processo.

## 2.2 Sistemas Biométricos

Uma importante tarefa no desenvolvimento de um sistema biométrico é determinar como um indivíduo será reconhecido. Dependendo do contexto da aplicação, o sistema biométrico pode ser classificado em sistema de verificação ou sistema de identificação.

Sistemas de verificação autenticam a identidade de uma pessoa comparando o traço biométrico capturado, com o modelo de referência biométrico capturado anteriormente, registrado no sistema. É feita uma comparação um-para-um (1:1) para confirmar a identidade do indivíduo. O sistema de verificação tanto aceita como rejeita o pedido de verificação de identidade.

Sistemas de identificação por sua vez reconhecem um indivíduo através de uma busca em todos os registros do banco de dados, retornando uma lista de registros com traços suficientemente similares ao traço biométrico apresentada. Essa abordagem é uma busca um-para-muitos (1:N), visando estabelecer se o indivíduo está presente no banco de dados e se estiver, retornar o identificador da referência de inscrição que é compatível (Maltoni et al., 2009).

Um sistema biométrico pode ser encarado como um sistema de reconhecimento de padrões de propósito específico (Bolle et al., 2002). Independente da finalidade, seu modelo conceitual leva em consideração os dados e processos básicos comuns a qualquer sistema biométrico. Em uma primeira utilização, o usuário é previamente registrado e seu perfil biométrico fica armazenado. Na utilização posterior do sistema, o processo de aquisição obtém os dados biométricos apresentados e características particulares dos dados são extraídas para comparação com o perfil armazenado. O processo de comparação decide se os dados apresentados são suficientemente similares ao perfil registrado (Costa et al., 2006).

Costa et al. (2006) definem cada etapa do modelo como segue:

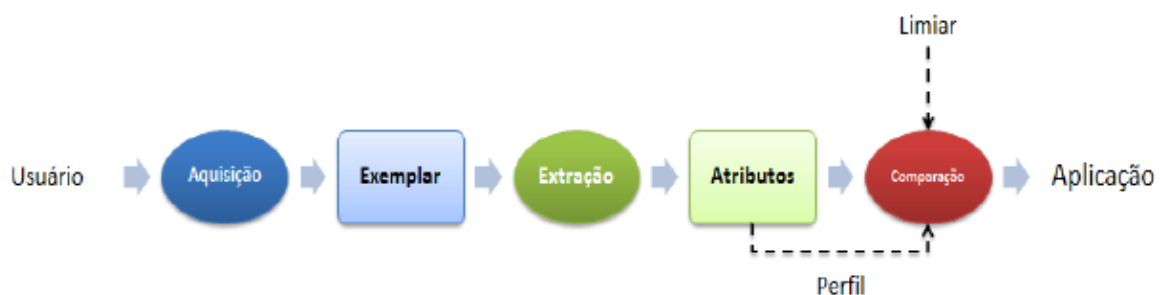
- *Aquisição e exemplar*: o processo de aquisição ou apresentação é o processo de obtenção dos dados do traço biométrico oferecido. Normalmente a dificuldade deste processo é balancear adequadamente a qualidade da amostra sem causar excesso de inconveniência para o usuário. Neste módulo é geralmente embutido um controle da qualidade da amostra adquirida (viabilidade de processamento). O exemplar ou amostra (*sample*) é o resultado do processo de aquisição.
- *Extração de atributos*: o processo de extração produz uma representação computacional do exemplar obtido, que chamaremos de atributos, ou características extraídas (*features*). A extração de características é a redução de um conjunto de medidas formado por uma grande quantidade de dados que contém uma pequena quantidade de informação útil para um conjunto que contém menos dados, mas praticamente a mesma quantidade de informação (Patrick, 1972).
- *Registro e perfil*: o processo de registro, ou *enrollment*, obtém previamente os dados biométricos do usuário para cadastramento no sistema. O perfil biométrico obtido,

ou *template*, é armazenado para uma comparação posterior. O processo de registro é necessário para o estabelecimento do perfil para posterior comparação.

- *Comparação, limiar e decisão*: O processo de comparação, ou *matching*, verifica qual é o grau de similaridade entre as características extraídas da amostra do usuário e o perfil armazenado previamente. Este processo fornece um escore representativo da similaridade entre os dois conjuntos de dados e segue a mesma lógica da binarização de imagens. Caso a similaridade seja superior a certo limite previamente determinado, conhecido como limiar, ou *threshold*, a decisão é aceitar o usuário, ou seja, uma autenticação válida. Caso a similaridade seja inferior ao limiar, a decisão é não aceitar o usuário, e então tem-se um usuário não autenticado.

A Figura 2.1 representa as etapas descritas anteriormente de um sistema biométrico.

Figura 2.1: Etapas de sistemas Biométricos. Adaptado de (Costa, et al., 2006)



Atualmente existem diversos tipos de sistemas biométricos. Para um sistema biométrico ser considerado prático, o mesmo deve ter uma precisão aceitável no reconhecimento e velocidade com necessidade de recursos razoáveis, deve ser inofensivo para os usuários, aceito pela população pretendida e suficientemente robusto aos vários métodos de fraude. A Figura 2.2 (Kulp, A. e Braskamp, H., 2012) mostra um gráfico comparativo entre alguns sistemas biométricos, considerando segurança *versus* conveniência.

Figura 2.2: Comparação de sistemas biométricos em relação à segurança e conveniência.

Fonte: Kulp e Braskamp (2012)



É possível também comparar os sistemas em relação ao seu custo e precisão como mostrado na Figura 2.3.

Figura 2.3: Comparação dos sistemas biométricos em relação ao custo e precisão. Fonte:

Kulp e Braskamp (2012)




Pode-se verificar que sistemas biométricos baseados em impressões digitais apesar de não serem tão convenientes quanto outros sistemas como face, onde não há a necessidade de contato com sensores, ainda possuem o melhor custo-benefício. Dessa forma, a impressão digital foi o traço biométrico utilizado neste trabalho e os seus detalhes e especificações estão descritos no próximo tópico.

## 2.3 Impressão Digital

Impressão digital é uma reprodução da aparência exterior da epiderme do dedo. A estrutura mais característica de uma impressão digital é o padrão intercalado entre cristas e vales. Em uma captura de impressão digital, as cristas são áreas escuras enquanto que os vales são as áreas claras (Figura 2.4). As cristas possuem diferentes espessuras, variando de  $100 \mu m$ , para as mais finas, até  $300 \mu m$ , para as mais largas. Geralmente, o período de ciclo crista/vale é aproximadamente  $500 \mu m$ . A maior parte das lesões encontradas no dedo, como queimaduras superficiais, abrasões ou cortes, não afetam a estrutura de saliência das cristas, e o padrão original é duplicado por toda a nova pele que cresce (Maltoni et al., 2009).

Figura 2.4: Cristas e vales de uma impressão digital. Fonte: Maltoni, 2009




Os detalhes das cristas são geralmente descritos em uma ordem hierárquica de três níveis diferentes, nomeados: Nível 1 (Padrão Global de disposição das cristas), Nível 2 (Minúcias), e Nível 3 (Poros, formato das arestas locais das cristas).

No nível global (Nível 1), as cristas geralmente se encontram paralelamente umas às outras, porém existem uma ou mais regiões onde eles assumem formas distintas (grande curvatura, maior quantidade de terminações, etc.). Essas regiões, chamadas de singularidades ou regiões singulares, são classificadas em três tipologias: *loop*, *delta* e *whorl* (Figura 2.5). Existem situações em que uma região *whorl* não é apresentada pois podem ser descritas como dois *loops*, um de frente para o outro (Maltoni et al., 2009).

Algoritmos de comparação de impressões digitais (algoritmos de *matching*) podem pré-alinhar as imagens baseados em um ponto central, chamado de *Core*, que pode ser definido

como o centro do *loop* mais ao norte da imagem. Existem, no entanto, imagens que não possuem singularidade do tipo *loop* ou *whorl*, nesse caso, o *core* é geralmente associado ao ponto máximo de curvatura das cristas. Contudo, devido à grande variação dos padrões das impressões digitais, muitas vezes, é uma tarefa difícil encontrar um *core* confiável em todas as amostras.


Figura 2.5: Regiões de singularidade (Caixas brancas) e pontos centrais (Círculos brancos) em impressões digitais. Fonte: Maltoni et al., 2009



No Nível 2, em um escopo menor, outras características podem ser encontradas, as minúcias. Minúcia significa pequeno detalhe e, no contexto das impressões digitais, refere-se às diferentes maneiras que uma crista pode ser descontinuada. Uma crista pode terminar subitamente (cristas finais), ou pode sofrer uma bifurcação e se dividir em duas cristas (cristas bifurcadas). As minúcias são as características mais utilizadas nos algoritmos de comparação de impressões digitais. Em uma impressão digital completa, onde a captura é feita por meio de rolagem do dedo, o número de minúcias encontradas pode ser maior que 100. No entanto, um pequeno número de minúcias corretamente correspondidas é suficiente para afirmar que as duas amostras são originadas do mesmo dedo. Existem diversos tipos diferentes de minúcias (Figura 2.6), embora apenas alguns tipos sejam utilizados (Maltoni et al., 2009).


O modelo utilizado pelo FBI (*Federal Bureau of Investigation*) baseado nas coordenadas das minúcias, utiliza apenas terminações e bifurcações de cristas. Cada minúcia é classificada pelas suas coordenadas baseadas nos eixos X e Y, e pelo ângulo da minúcia que tangencia as cristas (Figura 2.7).

Figura 2.6: Principais tipos de minúcias. Fonte: Maltoni et al., 2009



Foi adicionado o ângulo da minúcia como um atributo aos algoritmos de comparação de impressões digitais, devido à falta de precisão das minúcias capturadas, onde em algumas amostras, a variação da pressão do dedo sobre o sensor poderia dificultar a identificação de bifurcações e terminações, confundindo-os.


Figura 2.7: a) minúcia do tipo terminação:  $[x_0, y_0]$  são as coordenadas da minúcia,  $\theta$  é o ângulo que a tangente da minúcia forma com o eixo horizontal; b) minúcia do tipo bifurcação



Em um nível muito mais local está o Nível 3, onde detalhes mais finos podem ser extraídos de uma impressão digital. Nesse nível estão incluídos todos os atributos dimensionais das cristas, como largura, formato, contorno das bordas, poros, cristas novas, vincos e cicatrizes. Cada crista é dotada de poros em toda sua extensão. O tamanho dos poros pode variar entre 60 e 250  $\mu m$ . Estudos revelam que o número de poros por centímetro de crista varia entre 9 a 18 e estima-se que entre 20 e 40 poros são suficientes para determinar a identidade de um indivíduo. As características extraídas no Nível 3, apesar de serem extremamente distintivas e importantes para examinadores de impressões digitais, são pouco utilizadas nos algoritmos de comparação automática, uma vez que para obter uma detecção confiável, são necessários sensores de alta resolução que são mais caros e impressões digitais de boa qualidade. Na Figura 2.8 é possível observar os detalhes de uma impressão digital no Nível

3.

Figura 2.8: a) Parte de uma impressão digital, capturada a 1000 DPI, onde os poros ficam bem evidentes; b) Novas cristas; c) Vincos e cicatrizes



A seguir serão apresentadas as etapas utilizadas no processo de reconhecimento de indivíduos através da impressão digital.

## 2.4 Extração de Características

O processo de extração de características é o ponto central dos sistemas de autenticação baseados em impressões digitais, com implicações para o projeto do restante do sistema. As abordagens existentes são classificadas em três níveis, utilizando os níveis de detalhes das cristas vistos anteriormente: global, local e fina. A abordagem global descreve a formação geral das linhas. Geralmente, podem ser observados um núcleo e mais de dois deltas. Estas formações singulares são usadas como pontos de controle, em volta dos quais as linhas são organizadas. A orientação geral das linhas é útil para classificação e indexação em grandes grupos, embora não seja suficiente para comparação precisa.

A abordagem local está relacionada com detalhes marcantes das próprias linhas, as minúcias (*minutiae*). A extração destas características locais depende fortemente da qualidade da amostra adquirida.

A abordagem fina está baseada nos detalhes intra-linhas, que nada mais são que a posição e formação geral dos poros de suor, que medem cerca de  $60 \mu m$ . Embora tais características sejam altamente distintas, a sua extração somente é viável em imagens de alta resolução (cerca de 1.000 dpi) obtidas de impressões digitais de boa qualidade. A maioria dos sensores fornece imagens de resolução em torno de 500 dpi, assim, este tipo de representação não é prático para a maioria das aplicações (Costa et al., 2006).


Após a extração, as informações das digitais são salvas em um arquivo denominado *template* para facilitar o processo de desenvolvimento e testes dos algoritmos. Esses *templates* podem seguir um padrão próprio ou adotar o padrão ISO de *templates* para impressão digital. Esse padrão ajuda a promover a interoperabilidade entre os sistemas, visto que a extração de características provenientes de um sistema pode gerar um *template* que será usado por outro para aplicar o seu algoritmo de casamento. Além disso, ajuda a criar bancos de dados que podem ser usados por muitas instituições de pesquisa, competição ou governamentais. O padrão ISO utiliza apenas informações da abordagem local.

Com o objetivo de padronizar a geração de *templates* e comparar todos os algoritmos de forma justa, para o presente trabalho foram utilizados algoritmos de extração de características com abordagem local, apenas.

O desempenho dos algoritmos de extração de minúcias e outras técnicas de reconhecimento de impressões digitais depende muito da qualidade das imagens de impressões digitais de entrada. Em uma imagem de impressão digital ideal, cristas e vales se alternam e fluem em uma direção local constante. Nessas situações, as cristas podem ser facilmente detectadas e as minúcias podem ser localizadas precisamente na imagem. A Figura 2.9 (a) mostra um exemplo de uma impressão digital de boa qualidade. No entanto, na prática, devido às condições da pele (por exemplo, molhada ou seca, cortes, contusões, sujeira, cicatrizes), sensores de baixa qualidade que possuem ruído, pressão incorreta do dedo na aquisição, e dedos de baixa qualidade inerente (idosos, trabalhadores manuais), uma porcentagem significativa de imagens de impressões digitais (aproximadamente 10%) é de baixa qualidade como as mostradas nas Figura 2.9 (b), (c). Em muitos casos, uma única imagem de impressão digital contém regiões de boa, média e baixa qualidade onde o padrão das cristas é bastante ruidoso e corrompido (Maltoni et al., 2009). No geral, existem diferentes tipos de degradação associadas às imagens de impressão digital:

- As cristas não são estritamente contínuas, existem pequenas pausas.
- Cristas paralelas não são separadas de forma correta. Isso ocorre devido a presença de ruído que conecta cristas paralelas.
- Cortes, cicatrizes e hematomas no dedo.

Figura 2.9: Impressões digitais de qualidades diferentes




Esses três tipos de degradação tornam a extração de cristas extremamente difícil em regiões muito corrompidas. Isso leva aos seguintes problemas na extração de minúcias: (i) um número significativo de falsas minúcias é extraído, (ii) um grande número de minúcias genuínas é perdido, e (iii) vários erros na localização (posição e orientação) das minúcias são introduzidos. Buscando melhorar o desempenho dos algoritmos de extração de cristas e minúcias em imagens de impressões digitais de baixa qualidade, é necessário utilizar algoritmos de realce (*enhancement*) para melhorar a claridade da estrutura das cristas, sendo este o foco dessa pesquisa.

Um especialista em impressões digitais geralmente é capaz de identificar corretamente as minúcias utilizando várias indicações visuais como orientação local das cristas, continuidade de cristas, tendência da crista, entre outros. Na teoria, é possível desenvolver um algoritmo de realce que explora tais indicações para melhorar a qualidade da imagem. Geralmente, para uma imagem de impressão digital, existem regiões que podem ser classificadas em três diferentes categorias (Maltoni et al., 2009) (Figura 2.10):

- *Regiões bem definidas*: cristas podem ser claramente diferenciadas entre si.
- *Regiões recuperáveis*: cristas estão corrompidas por uma pequena quantidade de ruído, arranhões, manchas, mas ainda são visíveis e as regiões vizinhas provêm informações suficientes sobre a sua verdadeira estrutura.
- *Regiões irre recuperáveis*: cristas estão corrompidas por uma grande quantidade de ruído e distorção, tornando-se dificilmente visíveis, e as regiões vizinhas não são capazes de reconstruir a região de baixa qualidade.

Figura 2.10: Imagem de Impressão Digital com regiões de qualidades diferentes: a) região bem definida; b) região recuperável; c) região irrecuperável.



O principal objetivo do algoritmo de realce é melhorar a claridade da estrutura de cristas em regiões recuperáveis e marcar as regiões irrecuperáveis como regiões de muito ruído, retirando-as das futuras etapas de processamento.

As regiões de uma imagem de impressão digital podem ser identificadas utilizando vários critérios; em geral, os passos principais são: (i) normalização, onde os valores da intensidade dos pixels são padronizados (ii) estimativa da orientação, onde a orientação local das cristas é calculada, (iii) estimação da frequência das cristas, onde a frequência local das cristas é determinada, (iv) contraste da imagem, (v) segmentação, onde a região de interesse é determinada, separando a área da impressão digital do plano de fundo, (vi) binarização, onde os valores da escala de cinza da imagem são convertidos em uma imagem binária para facilitar a localização e identificação de cristas e vales e (vii) afinamento, que é uma operação morfológica que transforma as cristas em linhas de apenas um pixel, facilitando a determinação do pixel correspondente a uma minúcia (Kaggwa et al., 2014).

No tópico a seguir é apresentado o padrão ISO de *templates* que conforme mencionado anteriormente, facilita a interoperabilidade entre sistemas.

## 2.5 Padrão ISO de *templates*

O padrão ISO/IEC 19794-2:2005 especifica o formato dos dados para as representações de impressões digitais baseado em minúcias e define uma forma genérica para o seu armaze-

namento, de forma que possa conter informações de uma ou mais amostras de impressões digitais. Esse padrão estabelece informações importantes como: o tipo das minúcias, a posição e a orientação, e ainda especifica a forma que os dados serão armazenados (Araujo, 2015).

Segundo Maltoni et al. (2009), esse padrão ajuda a promover a interoperabilidade de sistemas, visto que diferentes algoritmos de casamento de impressões digitais podem utilizar qualquer *template* que adote o padrão ISO. Esse tipo de padrão costuma ser usado em bases de dados compartilhadas de instituições governamentais, acadêmicas ou em competições. Nesse tipo de base de dados, independente do algoritmo de extração de características, os algoritmos de casamentos são capazes de realizar comparações entre os diferentes tipos de *templates*. O padrão ISO utiliza apenas informações da abordagem local baseada em minúcias.

O formato de gravação baseado em minúcias define os elementos fundamentais usados para a representação de impressões digitais baseada em minúcias e outros dados opcionais como: contagem de cristas, informações acerca dos núcleos e das demais singularidades.

No cabeçalho desse arquivo ainda existem informações gerais a respeito da imagem, como: o tamanho da imagem e a quantidade de amostras presentes, onde, para cada amostra, existem informações sobre suas minúcias e informações adicionais.

Para cada minúcia, o espaço que é destinado a seu armazenamento contém:

- Tipo de Minúcia: O tipo da minúcia pode ser do tipo terminação e bifurcação. Além dos dois tipos de minúcias conhecidas, um tipo definido como "outro" identifica um tipo de minúcia que não pôde ser identificado com precisão, podendo pertencer a ambos os grupos ou ser tratada como uma minúcia desconhecida.
- Posição: A posição X e Y é expressa em pixels de acordo com as coordenadas do sistema.
- Orientação: A orientação da minúcia é gravada em unidades de bytes, conforme segue: 1.40625 (360/256) graus.
- Qualidade: A qualidade da minúcia indica a certeza da precisão de sua informação. Essa, por sua vez, é expressa entre 1 (qualidade mínima) e 100 (qualidade máxima) ou 0, se não há informações definidas de qualidade.

Outras informações sobre a contagem de cristas e núcleos das digitais também podem ser gravadas, a fim de serem usados para aumentar a confiabilidade dos algoritmos de casamento de impressões digitais.

Após a extração de características e conseqüentemente a criação dos *templates*, ocorre a etapa de comparação dos mesmos, também conhecida por casamento (*Matching*), determinando se as amostras pertencem à uma mesma pessoa. Os detalhes do algoritmo de comparação são apresentados no próximo tópico.

## 2.6 Matching

Um algoritmo de *Matching* (do português: Comparação, Casamento) de impressões digitais compara duas amostras e indica um grau de similaridade, geralmente um valor numérico entre 0 e 1 ou um valor booleano indicando se as impressões são iguais ou não. Apenas alguns algoritmos de casamento atuam diretamente nas imagens em escala de cinza geradas pelos sensores. A maioria deles utiliza como entrada o *template*, adquirido anteriormente na etapa de extração de características. Com isso, é de essencial importância que o algoritmo de extração seja confiável e possa gerar um *template* favorável ao algoritmo de *Matching*.

A comparação de imagens de impressões digitais é um problema difícil, devido principalmente à grande variedade nas amostras de impressões digitais de um mesmo dedo (e.g., amostras deslocadas, rotacionadas, com ruído) (Figura 2.11). No entanto, a maior incidência de erros na comparação ocorre devido aos erros provenientes da etapa de extração. Os algoritmos de extração de características são imperfeitos e geralmente apresentam falhas. Em imagens de baixa qualidade, o processo de extração de minúcias pode resultar em vários erros, detectando minúcias falsas e não detectando todas as minúcias genuínas existentes (Maltoni et al., 2009).

Existem muitos algoritmos de casamento de digitais propostos na literatura. A maior parte desses algoritmos não tem dificuldade ao comparar imagens de boa qualidade. Entretanto, o *Matching* de impressões digitais ainda é um desafio para imagens de baixa qualidade ou para imagens parciais de digitais. No caso de AFIS assistidos por pessoas, um algoritmo de checagem de qualidade pode ser usado para que apenas imagens de boa qualidade sejam usadas e armazenadas nos bancos de dados. Porém, a ação humana não é viável em siste-

Figura 2.11: amostras deslocadas, rotacionadas e com ruído



mas de reconhecimento biométricos autônomos, os quais são cada vez mais crescentes no mercado.

Uma análise de erros de Falsas Rejeições produzidas por vários algoritmos de *Matching* que participaram do FVC2000 mostrou que a maior parte dos erros ocorreram em 20% das imagens de baixa qualidade. Em outras palavras, 20% do banco de dados é responsável por 80% das Falsas Rejeições (Maltoni et al., 2009).

Com essas informações é possível deduzir que a presença de um algoritmo de extração de minúcias confiável é de suma importância para todo o processo, principalmente em imagens de baixa qualidade que possuem regiões irrecuperáveis, onde o processo de extração precisa identificar essas regiões e retirá-las, adicionando apenas regiões adequadas para o *template*.

Após a descrição do processo completo de reconhecimento de indivíduos, composto fundamentalmente pelas etapas de extração de características e comparação de *templates*, serão apresentadas as especificações sobre a forma de medição dos erros encontrados em um sistema biométrico, descritas no tópico a seguir.

## 2.7 Métricas de Erro

De acordo com Maltoni et al. (2009), espera-se em um cenário ideal que um sistema biométrico sempre ofereça o julgamento correto. No entanto, isso nem sempre acontece. Sistemas

biométricos são sistemas de reconhecimento de padrões que inevitavelmente podem produzir decisões incorretas. Além do mais, as premissas de singularidade e permanência dos atributos biométricos não são uma verdade absoluta na prática e ainda não se constituem em fatos científicos estabelecidos (Jain et al., 2011).

Os sistemas biométricos trabalham com as informações digitalizadas extraídas dos traços biométricos e não com os traços físicos em si e nesse processo pode haver variações nas medidas coletadas: seja por imperfeições no processo de captura, mudanças nas condições do ambiente ou mesmo alterações nas próprias características biométricas (Nascimento et al., 2015). Devido a essas alterações, duas amostras do mesmo usuário geralmente apresentam algumas divergências fazendo com que elas não sejam totalmente idênticas. Nesse contexto, algumas medidas de erro podem ser tomadas para avaliar a precisão do sistema de verificação biométrica.

O grau de semelhança entre duas digitais pode ser expresso através de um valor denominado *score*, de modo que quanto maior for o *score*, maior será as semelhanças entre duas amostras. O *score* de uma comparação pode ser Genuína ou Verdadeira, se for o resultado de duas amostras biométricas do mesmo indivíduo. E um *score* é conhecido como Impostor ou Falso, se envolve a comparação de duas amostras originadas de indivíduos diferentes. Um *score* de um impostor que excede um limiar  $N$  de *score* de aceitação gera uma Falsa Aceitação, enquanto um *score* verdadeiro que fica abaixo desse limiar caracteriza uma Falsa Rejeição.

O desempenho da verificação de sistemas biométricos geralmente é medido utilizando métricas como Taxa de Falsa Aceitação (do inglês, *False Acceptance Rate*, FAR), Taxa de Falsa Rejeição (do inglês, *False Rejection Rate*, FRR) e Taxa de Erro Igual (do inglês, *Equal Error Rate*, EER). Falsa aceitação ocorre quando um usuário não registrado obtém o acesso ao sistema protegido, enquanto falsa rejeição refere-se a quando um usuário registrado não consegue obter o acesso legítimo. A EER é geralmente utilizada para comparar o desempenho de diferentes sistemas biométricos e geralmente é calculada pelo ponto de interseção entre as curvas FAR e FRR, conforme indicado na Figura 2.12. Essas medidas são inversamente proporcionais à qualidade do desempenho do sistema biométrico.

De acordo com Ross et al. (2006), as taxas FAR e FRR podem ser calculadas pelas

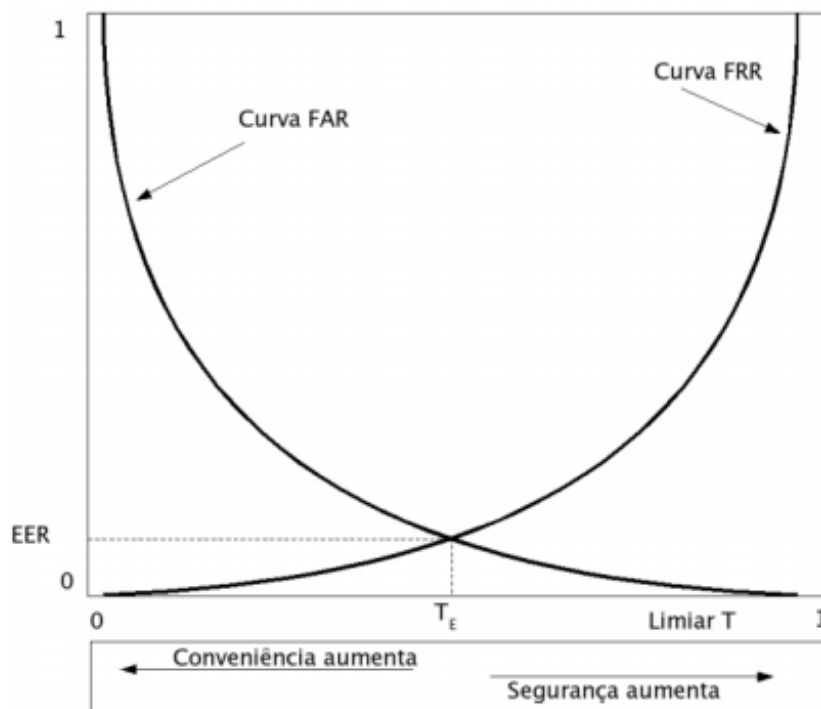
Equações:

$$FAR(\eta) = \int_{\eta}^{\infty} p(s|impostor) ds \quad (2.1)$$

$$FRR(\eta) = \int_{-\infty}^{\eta} p(s|impostor) ds \quad (2.2)$$

Em que  $p(s|impostor)$  e  $p(s|genuno)$  representam distribuições de probabilidade de um escore  $s$  sobre condições de genuíno e impostor, respectivamente, e  $\eta$  é um limiar que define se um indivíduo é genuíno (se  $s > \eta$ ) ou impostor.

Figura 2.12: As curvas típicas das taxas de erro FAR e FRR, plotadas uma ao lado da outra, em relação ao limiar  $T$  configurado para o sistema. O sistema pode operar nas faixas de “conveniência” ou de “segurança”, conforme a calibração do limiar. Fonte: Costa, Obelheiro e Fraga (2006).



É importante destacar que o ajuste do limiar permite a calibragem do sistema, mas também implica em consequências opostas. Sistemas onde brechas na segurança devem ser evitadas ao máximo (e.g., sistemas bancários), ajustam o limiar para que a FAR seja mínima. No entanto, isso pode resultar em problemas de conveniência, pois usuários genuínos pode-

rão ter seu acesso negado até que o sistema tenha a total certeza sobre o perfil do usuário. Por outro lado, sistemas que buscam minimizar a FRR no sentido de melhorar a conveniência de utilização por parte do usuário, poderão ter problemas de segurança, autorizando o acesso de usuários não legítimos.

Uma das formas mais confiáveis utilizadas para medir a eficácia de um sistema de reconhecimento de indivíduos por impressão digital é através da submissão do algoritmo para uma competição internacional, criada pelo conceituado BioLab, da Itália, que mede a precisão e velocidade desses algoritmos. Tal competição é conhecida pelo nome de FVC (*Fingerprint Verification Competition*) e os detalhes são descritos a seguir.

A *Fingerprint Verification Competition* (FVC) é uma competição internacional que tem o objetivo de avaliar softwares de Impressão Digital. Um subconjunto de Digitais é coletado a partir de vários sensores e é usado pelos participantes para que os parâmetros dos seus programas possam ser ajustados. Os participantes devem disponibilizar arquivos separadamente para as etapas de extração de características e de *Matching*; a avaliação é conduzida a partir desses arquivos sobre um conjunto de banco de dados criado a partir do mesmo conjunto de sensores que criaram o conjunto de testes.

A FVC é organizada por *Biometric System Laboratory (University of Bologna)*, *Pattern Recognition and Image Processing Laboratory (Michigan State University)*, *Biometric Test Center (San Jose State University)* e *Biometric Recognition Group - ATVS (Universidad Autonoma de Madrid)*. As quatro primeiras edições do FVC foram realizadas em 2000, 2002, 2004, 2006, respectivamente. Esses eventos receberam atenção das comunidades acadêmicas e industriais relacionadas com biometria. Eles estabeleceram uma referência, permitindo que desenvolvedores comparassem seus algoritmos e pudessem observar o estado da arte na área de reconhecimento de impressões digitais (FVC).

Após o evento de 2006, os organizadores da FVC criaram a *FVC-onGoing*, que possui algumas características diferentes em relação às competições anteriores. A *FVC-onGoing* não possui chamadas específicas e prazos de início e fim pré-determinados. É uma competição em curso, sempre aberta para o registro de novos participantes, onde os mesmos não possuem acesso ao conjunto de dados, que permanece isolado. Além disso, a *FVC-onGoing* não é voltada apenas para algoritmos de verificação de impressões digitais, são avaliados algoritmos de extração de orientação de imagens, extração de minúcias e indexação de impressões

digitais.

Nas próximas sessões são apresentados alguns conceitos e técnicas de processamento digital de imagens utilizados neste trabalho para a extração das características de impressões digitais e criação de *templates*.

## 2.8 Imagens e Processamento Digital de Imagens

Imagens são sinais, ou seja, funções que representam alguma informação a respeito de algo com um interesse. Uma imagem monocromática é uma função  $f(x, y)$  onde  $x$  e  $y$  representam as suas coordenadas espaciais e o valor de  $f(x, y)$  representa um valor de intensidade luminosa, geralmente chamada nível de cinza. Para serem representadas no computador, é necessário digitalizar as imagens, o que pode ser feito facilmente através dos processos de amostragem e quantização (Batista, 2005). Amostragem refere-se a capturar em intervalos de tempo iguais o sinal analógico que representa a imagem, enquanto que quantização refere-se a definir os valores que o sinal pode assumir no meio digital. O resultado de tais processos é uma imagem digital monocromática, representada da seguinte forma (Figura 2.13):

Figura 2.13: Exemplo matricial de imagem digital monocromática. Fonte: Batista, 2005.

$$\begin{pmatrix} f(0,0) & \dots & f(0, C-1) \\ \vdots & \ddots & \vdots \\ f(L-1, 0) & \dots & f(L-1, C-1) \end{pmatrix}$$

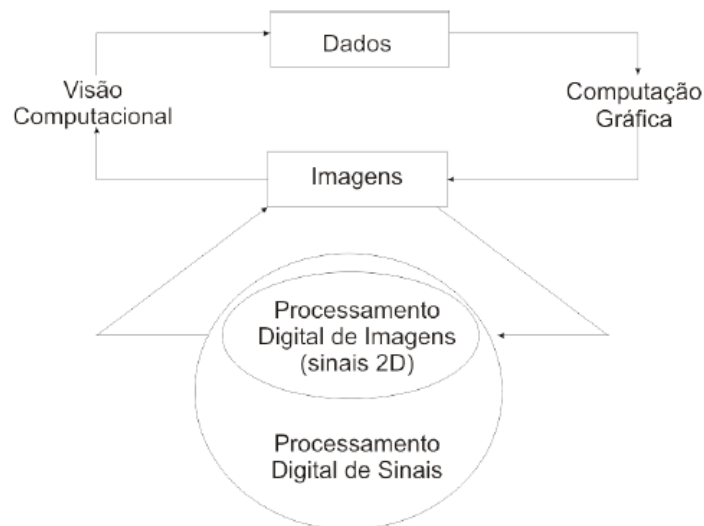
Os valores  $L$  e  $C$  representam, respectivamente, o número máximo de linhas e colunas da imagem digitalizada, e são determinados no processo de digitalização. Cada elemento da matriz  $f(i, j)$  é conhecido como pixel, e, como dito, representa o valor do nível de cinza naquele ponto. O número total de níveis de cinza  $N$  também é determinado no processo de digitalização. O menor valor é 0, e representa o preto, enquanto o maior valor,  $N - 1$ , representa o branco.

O Processamento Digital de Imagens (PDI) é a área da Ciência da Computação que se dedica ao processamento de imagens digitais em um computador digital (Gonzalez et al., 2004). Em síntese, pode-se dizer que o PDI consiste em qualquer forma de processamento de dados no qual a entrada e saída são imagens tais como fotografias ou quadros de vídeo.

Ao contrário do tratamento de imagens, que se preocupa somente com a manipulação de figuras para sua representação final, o PDI é um estágio para novos processamentos de dados tais como aprendizagem de máquina ou reconhecimento de padrões.

O Processamento Digital de Imagens é altamente multidisciplinar (Batista, 2005), e tem relações muito próximas com as áreas de Computação Gráfica (a qual consiste em obter imagens a partir de dados) e Visão Computacional (a qual consiste em obter dados a partir de imagens), como mostra a Figura 2.14. Muitas vezes um sistema de PDI exerce tarefas dessas duas áreas ao mesmo tempo. Outros exemplos de áreas ligados ao PDI são Inteligência Artificial, Animação, Reconhecimento de Padrões e a Indústria do Entretenimento.

Figura 2.14: Processamento digital de imagens e áreas correlatas. Fonte: Batista, 2005.




Nos tópicos a seguir algumas técnicas de processamento digital de imagens são apresentadas.

### 2.8.1 Binarização

A binarização, também conhecida como limiarização, é um método de segmentação de imagens que converte uma imagem para a forma binarizada, isto é, com somente dois valores para os pixels, o valor máximo ou o mínimo, tipicamente: preto ou branco. Para isso, o valor de um pixel é lido e comparado a um limiar definido anteriormente, se o valor do pixel atual é menor que o valor do limiar, o pixel é convertido para preto, caso contrário, é convertido para branco (Figura 2.15).


Figura 2.15: Exemplo de Binarização: (a) imagem original, (b) resultado da aplicação da binarização



### 2.8.2 Mediana

A mediana é um filtro de processamento digital de imagens que suaviza ruído, contribuindo em certos casos para uma análise mais precisa da informação. Ela é aplicada através de uma matriz, geralmente quadrada e de dimensões ímpares, onde os pontos da vizinhança de  $(i, j)$  são ordenados e o valor mediano é aplicado à imagem resultante no ponto  $(i, j)$ , como mostrado na Figura 2.16.

Figura 2.16: Exemplo de aplicação da mediana: (a) imagem original, (b) Resultado após a aplicação do filtro da mediana de tamanho 5x5



### 2.8.3 Segmentação

Uma das etapas mais importantes em sistemas automáticos de identificação de impressões digitais (AFIS) é a etapa de segmentação da impressão digital. Segmentação é a decomposição de uma imagem nos seus componentes. Uma imagem capturada de impressão digital geralmente é composta por dois componentes, que são chamados de *foreground* e *background*.

O *foreground* é o componente originado a partir do contato de um dedo com o sensor, é a região de interesse (*Region of Interest (ROI)*) para os sistemas. A área externa à impressão digital, geralmente composta por ruído, é o *background*.

O objetivo da segmentação é decidir que parte da imagem pertence à região de *foreground* e *background*. Uma segmentação eficiente é importante para a confiabilidade na etapa de extração de características, como minúcias ou poros. A maioria dos algoritmos de extração extraem um elevado número de falsas características quando são aplicados em áreas de ruído como as do *background*. Com isso, a segmentação busca descartar o *background*, reduzindo assim o número de falsas características extraídas (Bazen e Gerez, 2001). A Figura 2.17 mostra um exemplo de segmentação de uma imagem de impressão digital.

Figura 2.17: Segmentação de impressão digital



## 2.9 Coeficiente de Similaridade de Jaccard


O coeficiente de similaridade de Jaccard é uma técnica utilizada para medir o grau de similaridade e diversidade entre amostras finitas no processamento de dados. O coeficiente de Jaccard é obtido através da divisão entre o número de características que são comuns a todas

as amostras e o número total de características, resultado da união das amostras (Niwattanakul et al., 2013), como mostrado na Equação 2.3.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (2.3)$$

Definindo A e B como ROIs de uma impressão digital (Figura 2.18), o coeficiente de Jaccard atribui valor máximo ( $J(A, B) = 1$ ), quando as regiões são idênticas ( $|A \cap B| = |A \cup B|$ ), e atribui valor mínimo ( $J(A, B) = 0$ ), quando não existirem pixels em comum nas regiões ( $|A \cap B| = 0$ ).

Figura 2.18: Sobreposição de duas regiões de interesse de uma mesma impressão



Além da métrica de comparação de similaridade de Jaccard, uma outra forma de calcular o grau de semelhança entre as imagens foi utilizado neste trabalho, assim, a mesma será apresentada no tópico abaixo.

## 2.10 Métrica de Comparação de Thai et al.

Thai et al. (2016) propuseram a seguinte métrica para comparar o grau de similaridade entre duas imagens de segmentação de impressão digital: Sejam  $N_1$  e  $N_2$  a largura e a altura de uma imagem de impressão digital  $f$  em pixels. Seja  $E_f$  o número de pixels que são marcados como *foreground* por especialistas e estimados como *background* por algum algoritmo (*foreground* detectado/classificado incorretamente). Seja  $E_b$  o número de pixels marcados como

*background* por especialistas e estimados como *foreground* por algum algoritmo de segmentação (*background* detectado/classificado erroneamente). O erro total médio por imagem é mostrado na Equação 2.4

$$Erro = \frac{E_f + E_b}{N_1 \cdot N_2} \quad (2.4)$$


## 2.11 Filtros de Gabor

O Filtro de Gabor é um filtro linear usado para detecção de bordas. Ele é seletivo tanto em frequência quanto em orientação, e tem resolução conjunta ótima nos domínios espaciais e frequenciais (Maltoni et al., 2009). Como mostrado na Figura 2.19, um filtro de Gabor é definido por uma onda senoidal plana (o segundo termo da Equação (2.5) delimitada por uma curva gaussiana (o primeiro termo da Equação (2.5)). O filtro de Gabor bidimensional é dado por:

$$g(x, y, \theta, f) = \exp \left\{ \frac{-1}{2} \left[ \frac{x_\theta^2}{\sigma_x^2} + \frac{y_\theta^2}{\sigma_y^2} \right] \right\} \cdot \cos(2\pi f x_\theta) \quad (2.5)$$

Em que  $\theta$  é a orientação do filtro, e  $[x_\theta, y_\theta]$  são as coordenadas de  $[x, y]$  depois de uma rotação no sentido horário dos eixos cartesianos por um ângulo de  $(90^\circ - \theta)$ , é a frequência da onda senoidal plana,  $\sigma_x$  e  $\sigma_y$  são os desvios padrão da curva gaussiana sobre os eixos  $x$  e  $y$ , respectivamente.


Figura 2.19: Representação gráfica (visão lateral e superior) do filtro de Gabor. Fonte: Maltoni et al., 2009.



Um dos métodos mais comuns na literatura para realce de impressões digitais é através da convolução de imagens com filtros de Gabor. Utilizando parâmetros coerentes e sucessivas iterações, é possível destacar nitidamente as linhas presentes nas imagens.


Para tornar o algoritmo de realce mais rápido, ao invés de calcular o filtro ideal para cada pixel em tempo de execução, um conjunto  $\{g_{i,j}(x,y) | i = 1..n, j = 1..n\}$  de filtros são previamente criados e armazenados, onde  $n_o$  é o número de orientações  $\{\theta_i | i = 1..n_o\}$  e  $n_f$  é o número de frequências  $\{f_j | j = 1..n_f\}$ . Então, cada pixel  $[x, y]$  é convoluído com o filtro  $g_{i,j}(x, y)$ . A Figura 2.20 mostra um exemplo de um conjunto de filtros com  $n_o = 8$  e  $n_f = 3$ .

Figura 2.20: Um conjunto de filtros de Gabor com seis orientações  $\theta$  (colunas) e 3 frequências  $f$  (linhas) Fonte: Maltoni et al., 2009.



Cada convolução com uma máscara de Gabor destaca uma orientação diferente na imagem da digital, variando a orientação do filtro de 0 a  $\pi$ . Tratando os resultados é possível destacar todos os contornos. A Figura 2.21 ilustra este processo, usando um passo de  $\frac{\pi}{12}$  radianos.

Figura 2.21: Convolução com filtros de Gabor de diferentes orientações



## 2.12 Envoltório Convexo


O problema do envoltório convexo (do inglês: *Convex Hull*) foi um dos primeiros problemas do campo de geometria computacional estudado, do ponto de vista de complexidade computacional.

A função envoltória convexa de um conjunto finito de pontos  $s$  em um plano é o menor polígono convexo que contém todos os pontos de  $s$ . Os vértices desse polígono devem ser pontos que estão contidos no conjunto. Para calcular a função envoltória convexa é necessário encontrar os pontos que serão parte dos vértices limitadores do polígono (Kirkpatrick e Seidel, 1986).

Segundo o'Rourke (1998) é possível implementar a função envoltória convexa com complexidade  $O(n^2)$  em um espaço tridimensional. Essa função é capaz de trabalhar eficientemente em um espaço de 2 a 8 dimensões (Barber et al., 1996).

A Figura 2.22 exemplifica a aplicação do método em conjuntos de pontos em espaços dimensionais variados. A Figura 2.22(a) mostra um conjunto de pontos após a aplicação da envoltória convexa criando um polígono que contém todos os pontos. O mesmo pode ser feito em estruturas tridimensionais como mostra a Figura 2.22(b).

Figura 2.22: a) e c) Exemplos de pontos em um plano bidimensional contidos em um espaço definidos pela função envoltória convexa. b) Envoltória convexa em um espaço tridimensional. Fonte: (Weisstein, 2016)



# Capítulo 3

## Trabalhos Relacionados

Nessa seção são descritos alguns trabalhos relacionados ao presente estudo. Primeiramente, pesquisas relacionadas aos algoritmos de realce (*enhancement*) de impressões digitais são citados, assim como estudos que realizam comparações entre algoritmos de pré-processamento e extração de características de impressões digitais. Em seguida, serão apresentados trabalhos que realizam a segmentação de impressões digitais.

### 3.1 Trabalhos relacionados sobre o tema Enhancement

A maior parte dos trabalhos sobre métodos de realce e melhoria de qualidade de impressões digitais explora informações contextuais (Maltoni et al., 2009). O contexto é normalmente representado pela orientação, frequência e qualidade local e é utilizado para adaptar as características do filtro a cada região da impressão digital. Um dos métodos de filtragem contextual mais utilizado baseia-se em filtros de Gabor, tal como proposto por Hong et al. (1998).

Filtros de Gabor têm ambas as propriedades de frequência e orientação seletiva e têm resolução conjunta ideal em ambos os domínios espaciais e de frequência. Abordagens de filtragem no domínio da frequência ou em uma mistura de domínio de frequência espacial têm sido propostos por vários autores como Sherlock et al. (1994), Jirachaweng e Areekul (2007) e Chikkerur et al. (2007). O método de *enhancement* apresentado por Turrone et al. (2012), mostra-se bastante eficiente. Seu método consiste em uma filtragem contextual de acordo com utilização de Gabor iterativo. Porém esse método possui algumas deficiências

em relação à abordagem de aplicação do filtro de Gabor, além de possuir tempo de processamento demasiadamente demorado.

No trabalho de Shen e Eshera (2004), são descritos alguns métodos para extrair características de impressões digitais através de um mapeamento dessas características no domínio do espaço, utilizando técnicas de pré-processamento, direção e espessura de cristas, realce e detecção de minúcias.

## 3.2 Trabalhos relacionados sobre o tema ROI

De acordo com Msiza et al. (2011), que realizaram um estudo sobre as várias técnicas diferentes de segmentação de impressões digitais, a maioria dessas técnicas existentes pode ser organizada em três categorias principais: Abordagem baseada em pixels (*Pixel-Based* (P-B)), baseada em blocos (*Block-Based* (B-B)) e baseada em grafos (*Graph-Based* (G-B)). Um algoritmo de segmentação P-B busca determinar quais pixels da imagem pertencem ao *foreground*, que é a área que realmente interessa, e quais pertencem ao *background*, que é o plano de fundo, a parte irrelevante da imagem. Embora esse método de segmentação possa ser mais preciso, o mesmo possui um alto custo computacional, uma vez que precisa avaliar um elevado número de pixels (Msiza et al., 2011).

Existem alguns exemplos onde os algoritmos P-B obtiveram sucesso em segmentação de impressões digitais. Em 2001, Bazen e Gerez (2001) utilizaram três características dos pixels para treinar um classificador linear, de maneira supervisionada, com intuito de segmentar uma imagem de impressão digital. Essas três características foram: coerência, média e desvio padrão (variância). O classificador linear foi escolhido para reduzir a complexidade computacional. A segmentação de imagens utilizando essa técnica obteve bons resultados ao ser comparada com segmentações feitas manualmente (Msiza et al., 2011).

Cinco anos depois de Bazen e Gerez (2001) terem publicado o seu trabalho, Rojas et al. (2006) propuseram uma melhoria ao algoritmo que tratava os casos em que as classes poderiam não ser linearmente separáveis, resultando em falhas no classificador linear. Esse algoritmo melhorado foi implementado com a técnica de aprendizado *Fuzzy Perceptron*. Outros métodos de segmentação de impressões digitais utilizando a abordagem P-B são utilizados nos trabalhos de Koh et al. (1995), Pappas (1992), Ghosh et al. (1991) e Shu et al. (2009).

A segmentação por Blocos (B-B) processa a imagem por blocos de pixels. O objetivo maior dessa abordagem é reduzir o custo computacional que ocorre com os algoritmos mais tradicionais que usam abordagem P-B. Contudo, apesar dessa abordagem acelerar o processo, a mesma tem como desvantagem o fato de reduzir a precisão da segmentação. Isso significa que, quando comparado com abordagens P-B, a abordagem B-B é mais rápida, porém menos precisa.

Uma revisão na literatura nos mostra que existe um considerável número de algoritmos B-B que obtiveram bons resultados na segmentação de impressões digitais. Em 1995, Ratha et al. (1995) apresentaram um método que utilizava variância em níveis de cinza em uma direção perpendicular à orientação das cristas. Neste estudo, a imagem foi dividida em blocos 16x16, no entanto, não existem explicações formais sobre como chegaram nessa definição de tamanho de bloco. Outro estudo interessante foi conduzido por Maio e Maltoni (1997), onde eles computaram o gradiente médio de cada bloco para poder separar o *foreground* do *background*. A ideia partia do pressuposto que a região da impressão digital (*foreground*) possuía uma resposta maior ao gradiente, enquanto que o plano de fundo possuía uma resposta muito baixa. Da mesma forma, não existe definição formal sobre como chegaram no tamanho do bloco.

Em 2001, Shen et al. (2001) introduziram a ideia de convolução para segmentar a imagem. Cada bloco de pixels era convoluído com uma série de filtros de Gabor e a variância das respostas desses filtros era usada para realizar a segmentação, contudo, mais uma vez, os autores não especificaram como o tamanho do bloco de pixels foi definido.

Os algoritmos de segmentação com abordagem G-B modelam a imagem utilizando a teoria dos grafos. A imagem é representada como um grafo unidirecional com pesos,  $G = (V, E)$ , onde  $V$  é o conjunto de nós e  $E$  é o conjunto de arestas. Cada nó representa um pixel na imagem enquanto que uma aresta é a ligação entre os pares de nós. Cada aresta conectando os nós  $i$  e  $j$  é associada com um peso,  $w(i, j)$ , que pode ser caracterizado como uma propriedade entre nós conectados (Msiza et al., 2011). Os algoritmos de segmentação G-B não são tão eficazes com relação à segmentação de impressões digitais, assim, não entraremos em muitos detalhes nessa abordagem neste trabalho.

Os algoritmos de segmentação recentes, classificados como estado da arte serão descritos nos parágrafos a seguir.

Sankaran et al. (2017) propuseram um novo método para segmentar impressões digitais latentes utilizando algoritmos de aprendizagem de máquina para poder distinguir entre padrões com cristas e padrões sem cristas. Um classificador de árvore de decisão foi utilizado para segmentar a imagem em blocos de *foreground* e *background*, obtendo taxas de acurácia de segmentação em torno de 96% na base de dados do NIST (*National Institute of Standards and Technology*), mais precisamente a base NIST SD-4.

Fleyeh (2016) propôs um algoritmo que utiliza um limiar adaptativo que busca ajustar uma curva entre os níveis de cinza dos pixels em cada linha ou coluna de imagens de impressões digitais. A curva representa o limite de binarização de cada pixel na linha ou coluna correspondente.

Carneiro et al. (2014) desenvolveram um estudo comparativo para analisar quatro técnicas de limiarização (Niblack, Bernsen, Fisher, Fuzzy), duas técnicas de afinamento (Stentiford e Holt) e uma técnica de extração de características (*Cross Number*) para aplicações com segmentação de impressões digitais. Os autores testaram e analisaram os algoritmos através de um conjunto de 160 imagens de impressões digitais. Os resultados apontaram os lados positivos e negativos de cada um dos algoritmos.

Thai et al. (2016) propuseram um novo método de segmentação chamado *Factorized directional bandpass* (FDB) baseado no filtro direcional *Directional Hilbert Butterworth Bandpass filter* (DHBB) entrelaçado com um limiar suave. Além disso eles também fizeram a segmentação manual de 10560 imagens, e conduziram um método de comparação sistemático para comparar o algoritmo de segmentação deles com outros algoritmos considerados os mais citados na área de segmentação de impressão digitais. Eles obtiveram resultados relevantes, mostrando que o método desenvolvido é claramente mais eficaz que os outros citados e considerados o estado da arte. Além disso, o trabalho desses autores foi de grande contribuição, uma vez que disponibilizaram as imagens segmentadas manualmente, facilitando que novos pesquisadores realizem trabalhos futuros de comparação entre os algoritmos utilizando este gabarito.

Thai e Gottschlich (2016) desenvolveram um método de segmentação chamado *Global three-Part Decomposition* (G3PD). O método criado foi avaliado utilizando o sistema de comparação criado por Thai et al. (2016). Os resultados mostraram que eles obtiveram melhores taxas de acerto em comparação com o método FDB, se tornando assim o método de

segmentação de impressões digitais mais bem ranqueado.

Por esse motivo, o método de segmentação criado neste presente trabalho será comparado com o G3PD, FDB e outros algoritmos presentes nos trabalhos de Bazen e Gerez (2001), Shen et al. (2001), Wu et al. (2007) e Chikkerur et al. (2007), que foram incluídos no sistema de comparação desenvolvido por Thai et al. (2016).

A Tabela 3.1 mostra alguns resultados obtidos pelos principais métodos de segmentação na literatura.

Tabela 3.1: Principais algoritmos de segmentação e seus resultados obtidos através da comparação com segmentações manuais, como é o caso dos algoritmos testados através da métrica de avaliação de Thai et al. (2016) e comparações visuais.

<b>Algoritmo</b>	<b>Ano</b>	<b>Técnicas Utilizadas</b>	<b>Métrica de Avaliação</b>	<b>Resultados</b>	<b>Bases de Dados</b>
Bazen e Gerez	2001	Atributos de Pixels	Thai et al. (2016)	93,49%	12 bases de dados FVC
Shen et al.	2001	Banco de Filtros de Gabor	Thai et al. (2016)	91,67%	12 bases de dados FVC
Wu et al.	2007	Respostas das bordas de Harris (1988)	Thai et al. (2016)	94,22%	12 bases de dados FVC
Chikkerur et al.	2007	Transformadas de Fourier	Thai et al. (2016)	92,43%	12 bases de dados FVC
Thai et al.	2016	Filtro direcional de Hilbert	Thai et al. (2016)	96,70%	12 bases de dados FVC
Thai e Gottschlich	2016	Decomposição global em três partes	Thai et al. (2016)	96,94%	12 bases de dados FVC
Fleyeh	2016	Limiar adaptativo	Comparação Visual	96%	2 bases de dados FVC
Sankaran et al.	2017	Aprendizagem de Máquina	Comparação Visual	96%	Base de dados do NIST

Um breve levantamento realizado na literatura mostrou que existem diversas abordagens que obtiveram sucesso ao aplicar filtros de Gabor no domínio da frequência ou mesclando domínio da frequência e domínio do espaço para realçar imagens de impressões digitais, sendo exploradas por alguns autores Sherlock et al. (1994), Chikkerur et al. (2007), Jirachaweng e Areekul (2007) e Hsieh et al. (2003). No entanto, nesses estudos, os filtros de Gabor foram utilizados apenas para realçar a impressão digital, ao invés de serem utilizados para segmentação, como é proposto neste trabalho. Os filtros de Gabor são a base para o método proposto tanto de segmentação, quanto de realce, e serão descritos com mais detalhes no capítulo seguinte.

# Capítulo 4

## Metodologia

Este capítulo descreve os métodos desenvolvidos e os recursos utilizados. Inicialmente, o ambiente de desenvolvimento é apresentado, seguido pela descrição do método proposto e a metodologia de validação.

### 4.1 Ambiente de Desenvolvimento

Foi utilizada a IDE Visual Studio 2015 com as linguagens de programação C++ e C#, instalada em um computador com processador Intel® Core™ i7-3537U 2.0 GHz, 8GB de memória RAM DDR3, sistema operacional Microsoft® Windows 8.1 de 64 bits. Foi desenvolvido um projeto juntamente com a equipe de desenvolvedores da Vsoft Tecnologia para realizar a manipulação das imagens de impressão digital, aplicação dos algoritmos, armazenamento e leitura de *templates* em banco de dados, verificação de tempo, taxas de erro e plotagem de gráficos.

### 4.2 Método Proposto

Este trabalho propõe uma nova abordagem para a etapa de extração de características de impressões digitais, que juntamente com a etapa de *matching* forma um sistema completo de identificação automática de impressões digitais (*Automated Fingerprint Identification System* - AFIS).

Como foi mencionado em capítulos anteriores, a etapa de extração de características

depende bastante da qualidade da imagem de impressão digital para que as características importantes possam de fato ser extraídas, e características descartáveis, como ruído, plano de fundo, cortes e etc, possam ser removidas. Dessa forma, foi desenvolvido um algoritmo que realiza diversas etapas para melhoria da qualidade da imagem e posterior extração de informações, visando reduzir os erros na identificação de indivíduos. O desenvolvimento deste método pode ser dividido nas seguintes etapas:

- Segmentação da região de interesse;
- Realce por filtros de Gabor;
- Afinamento;
- Localização das minúcias;
- Filtragem das minúcias.

Observando a literatura notou-se que algumas dessas etapas já possuem métodos bastante consolidados e aceitos por toda a comunidade. São as etapas de pré-processamento, afinamento, localização e filtragem das minúcias. Dessa forma, para essas etapas foi utilizado o que já existe na literatura e apenas uma breve explicação sobre os passos foi dada. O foco, portanto, deste trabalho, está na melhoria das etapas de segmentação e realce da impressão digital, uma vez que as mesmas ainda representam o maior gargalo nos erros de identificação de indivíduos. Na próxima seção cada uma das etapas é apresentada e detalhada.

### **4.3 Segmentação da Região de Interesse**

A primeira etapa do algoritmo de extração desenvolvido neste trabalho consiste em uma segmentação da imagem original, com o objetivo de separar a Região de Interesse e diminuir o processamento em etapas posteriores. Nesta seção os passos do algoritmo de ROI são descritos, assim como a metodologia utilizada para avaliação e comparação com alguns trabalhos relacionados.

### 4.3.1 Abordagem Proposta

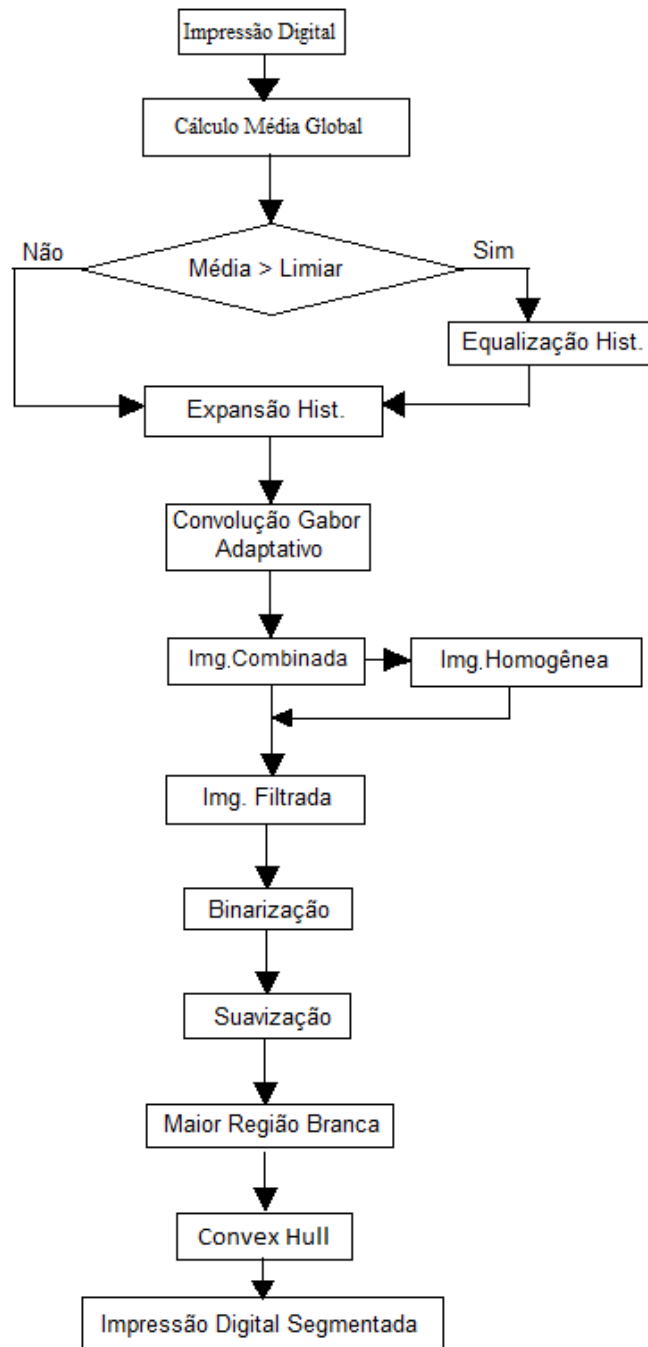
A segmentação da imagem de impressão digital é uma das etapas mais importantes para o sistema completo de identificação de indivíduos. Uma segmentação feita de forma incorreta pode resultar em extração de características falsas ou até mesmo suprimir informações de características verdadeiras.

Existem basicamente dois conceitos em relação à segmentação de impressões digitais, que não estão muito claros na literatura. O primeiro conceito e também o mais aceito é a divisão da impressão digital em *background* e *foreground*. O outro conceito consiste na seleção das regiões da imagem de impressão digital que são de boa qualidade, sejam regiões bem definidas ou recuperáveis, excluindo as regiões irrecuperáveis. Neste trabalho foram utilizados os dois conceitos, com propósitos distintos que serão apresentados nos parágrafos seguintes.

A definição da ROI utilizada neste trabalho é baseada no trabalho de Turrone et al. (2012), que realiza convolução da imagem de impressão digital de entrada com filtros de Gabor de forma iterativa, no entanto, os autores utilizam os filtros de Gabor com o intuito de realizar realce da imagem (*enhancement*) e não para a extração da ROI, como foi realizado no presente trabalho.

O fluxograma completo da abordagem realizada é apresentado na Figura 4.1, seguido por uma explicação detalhada dos passos individuais.

Figura 4.1: Fluxograma com todos os passos realizados no método de segmentação desenvolvido




**Pré-Processamento.** Muitas imagens de impressões digitais são capturadas em condições adversas e dessa forma são difíceis de terem suas características extraídas. Um dos principais problemas ocorre quando a imagem é muito clara ou muito escura, ou seja, com baixo contraste, dificultando a segmentação em plano de fundo e região de interesse. Para au-

mentar o contraste da imagem de impressão digital, é necessário realizar algumas operações como equalização e expansão de histogramas. No entanto, algumas imagens de impressões digitais já possuem um contraste satisfatório e não necessitam de operações que o aumentem como as mencionadas acima, uma vez que essas operações, principalmente a equalização de histograma, podem aumentar a quantidade de ruído na imagem e tornar a tarefa de segmentação mais árdua.

Com o intuito de determinar automaticamente a necessidade da aplicação da equalização de histograma, foi calculada a média dos valores de níveis de cinza dos pixels para cada imagem. Se uma grande quantidade de pixels tem o nível de cinza próximo da média, a operação de equalização de histograma é aplicada, caso contrário, apenas a operação de expansão de histograma é realizada. Essa quantidade de pixels é determinada por um limiar, que foi empiricamente definido como 80%. Sendo  $G$  a média global, então uma faixa de  $n$  níveis de cinza na vizinhança de  $G$  é definida como  $[G - \frac{n}{2}, G + \frac{n}{2}]$ . Isso significa que para a condição ser aceita, mais de 80% dos pixels devem possuir níveis de cinza na faixa  $\pm \frac{n}{2}$  de  $G$ . Logo após essa etapa, a operação de expansão de histograma local é aplicada sobre a imagem de impressão digital (Figura 4.6(b)). Ambas as operações de histograma são realizadas por blocos, cujo tamanho foi definido empiricamente.


A Figura 4.2 mostra duas imagens de impressões digitais de diferentes bases de dados: uma que necessita de equalização de histograma (Figura 4.2(a)) e outra que não precisa (Figura 4.2(c)). As Figuras 4.2(b,d) mostram o resultado da aplicação de equalização de histograma nas impressões digitais das Figuras 4.2(c,d), respectivamente. Observa-se que na Figura 4.2(a), o contraste da imagem é aumentado e a diferença entre *background* e *foreground* é enfatizada, já para a Figura 4.2(c), uma grande quantidade de ruído é inserida na imagem de saída, dificultando a identificação da região de interesse.

Figura 4.2: Exemplos de equalização de histograma sobre diferentes imagens de impressões digitais. (a) Impressão digital 27\_8.bmp da base de dados FVC2002-1, (b) imagem de saída da impressão digital após a aplicação da operação de equalização de histograma, (c) Impressão digital 5\_7.bmp da base de dados FVC2000-3, (d) imagem de saída da impressão digital 5\_7.bmp após a aplicação da equalização de histograma.



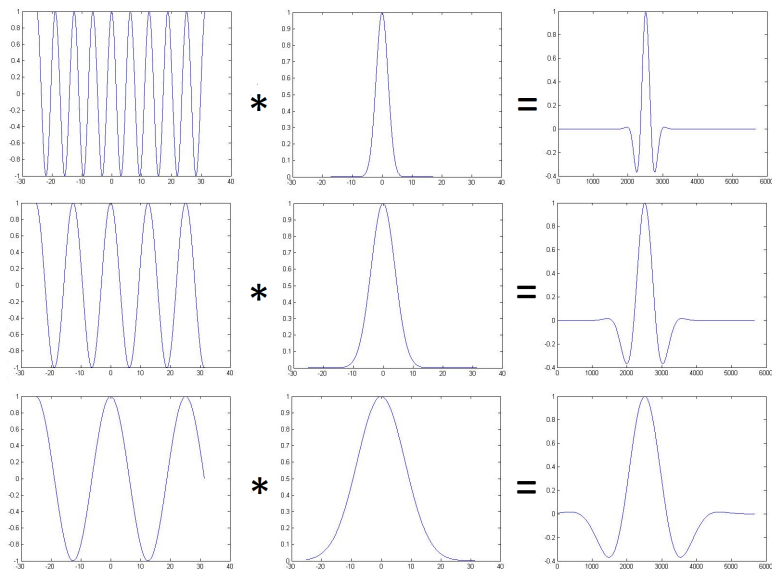
**Convolução com um banco de máscaras de Gabor adaptativas.** Após a etapa de pré-processamento de histograma, são definidos parâmetros para a construção de  $n$  máscaras de Gabor para a convolução com a imagem de impressão digital. Esses parâmetros foram definidos como  $n_o = 8$  para a orientação e  $n_f = 3$  para a frequência, com o objetivo de reproduzir a quantidade de máscaras utilizadas no trabalho de Turrone et al. (2012). A diferença entre as máscaras utilizadas por Turrone et al. (2012) e as utilizadas nesse presente trabalho é o desvio padrão que aqui é definido dinamicamente. Enquanto Turrone et al. (2012) e Hong et al. (1998) usam um valor fixo de  $\sigma_x$  e  $\sigma_y$ . O algoritmo proposto determina o desvio padrão de acordo com a frequência  $f$  da máscara. A Figura 4.3 mostra os sinais gerados pela Equação 2.5 usando desvio padrão fixo e diferentes frequências.

Figura 4.3: Sinais de saída do filtro de Gabor utilizando frequências diferentes e  $\sigma$  fixo



A Figura 4.4 mostra os sinais de Gabor gerados utilizando o desvio padrão baseado nos valores de frequência.

Figura 4.4: Sinal de saída do filtro de Gabor utilizando frequências diferentes e  $\sigma$  definido dinamicamente de forma adaptativa.



Como pode ser observado, existe uma diferença entre as duas abordagens, na Figura 4.3 os sinais de saída diferem devido às diferentes frequências testadas, enquanto que na Figura 4.4 os sinais de saída são bastante similares mesmo com frequências diferentes.


Notou-se que ao utilizar um  $\sigma$  fixo, são geradas máscaras de Gabor que, quando convoluídas com as imagens de impressões digitais, trazem resultados insatisfatórios. Frequências altas criam mais linhas do que as frequências mais baixas quando multiplicadas por um  $\sigma$  fixo, o que implica em uma maior dificuldade para casar os padrões e obter boas respostas com máscaras de frequência elevada.

**Imagem combinada.** Após a criação das máscaras de Gabor, a imagem de impressão digital é convoluída com todas as máscaras. O conjunto das  $n$  imagens resultantes da convolução é utilizado para formar a imagem combinada, onde cada pixel é a resposta máxima dentre os pixels na mesma posição das imagens resultantes das convoluções (Figura 4.6c), i.e.:

$$C(i, j) = \max(|g_1(i, j)|, |g_2(i, j)|, \dots, |g_n(i, j)|) \quad (4.1)$$

Os valores dos pixels da imagem combinada são normalizados para a faixa de valores  $[0,1]$ , onde 0 representa a resposta mínima para os filtros de Gabor (baixa evidência de cristas ou vales) e 1 representa a resposta máxima ao filtro de Gabor (alta evidência de cristas ou vales). As Figuras 4.5(a,b) são as imagens combinadas resultantes da imagem de impressão digital 11\_5.bmp da base de dados FVC2000-3 DBA. Na Figura 4.5(a) foram utilizados  $\sigma_x$  e  $\sigma_y$  fixos, com valores definidos por Hong et al. (1998) e Turroni et al. (2012), enquanto que na Figura 4.5(b), foi utilizado o filtro de Gabor adaptativo desenvolvido neste trabalho com  $\sigma_x$  e  $\sigma_y$  definidos dinamicamente. As Figuras 4.5(c,d) utilizam a mesma abordagem, neste caso, para a imagem 23\_5.bmp da base de dados FVC2000\_4. É possível observar que as imagens combinadas obtidas através da convolução com o filtro de Gabor adaptativo (Figuras 4.5(b,d)) obtiveram melhores respostas na região de *foreground* e piores respostas na região de *background* quando comparadas com as imagens resultantes da aplicação de filtros de Gabor com  $\sigma$  fixo. Esse é exatamente o propósito desta abordagem, facilitar a separação entre *foreground* e *background*.

Figura 4.5: Imagens Combinadas utilizando  $\sigma$  fixo (a,c) e  $\sigma$  definido dinamicamente de forma adaptativa (b,d)



**Imagem de Homogeneidade** Além dos passos anteriores, também foi utilizado o conceito da imagem de Homogeneidade definida por Turrone et al. (2012). A imagem de Homogeneidade  $H = \{h_{x,y} | x = 1..w, y = 1..h\}$  calcula a homogeneidade do fluxo das cristas em uma determinada região da imagem, verificando se não existem mudanças abruptas. De acordo com Turrone et al. (2012), a princípio, exceto pelas regiões de singularidade, as cristas fluem suavemente através do padrão da impressão digital, e mudanças abruptas na orientação e na frequência não devem existir. Isso significa que casos existam essas descontinuidades, elas são ocasionadas por ruído ou mudanças de cristas por arranhões ou cicatrizes. Buscando separar o *background* do *foreground*, foi utilizada a imagem de homogeneidade devido ao fato da região de *background* muitas vezes possuir uma grande quantidade de ruído e regiões descontínuas. A homogeneidade no ponto  $[x, y]$  é definida por:

$$h_{x,y} = \frac{\sum_{p,k} C_{p,k} \cdot S_{p,k}}{\sum_{p,k} C_{p,k}} \quad (4.2)$$

onde  $p$  e  $k$  estão na faixa entre  $[-\frac{m}{2}, +\frac{m}{2}]$  e  $S_{p,k}$  é a medida de orientação de homogeneidade

definida como:

$$S_{p,k} = \frac{\pi}{2} - |\Delta\phi(O_{x,y}, O_{p,k})|$$

$$\Delta\phi(\theta_1, \theta_2) = \begin{cases} \theta_1 - \theta_2 & , se -\frac{\pi}{2} \leq \theta_1 - \theta_2 < \frac{\pi}{2} \\ \pi + \theta_1 - \theta_2 & , se \theta_1 - \theta_2 < -\frac{\pi}{2} \\ \pi - \theta_1 - \theta_2 & , se \theta_1 - \theta_2 \geq \frac{\pi}{2} \end{cases} \quad (4.3)$$

A Figura 4.6(d) mostra um exemplo de imagem de homogeneidade. Os pixels brancos representam boas respostas, demonstrando uma região contínua, sem descontinuidades de ângulos.

**Imagem Filtrada.** A próxima etapa é uma operação para determinar quais regiões são consideradas boas para serem selecionadas como *foreground* de acordo com as respostas obtidas pelas imagens combinadas e de homogeneidade (Figura 4.6(e)). A imagem filtrada é definida por:

$$F_{i,j} = C_{i,j} \cdot h_{i,j} \quad (4.4)$$

Em que  $C$  é a imagem combinada e  $H$  é a imagem de homogeneidade.

**Binarização.** Logo após, é aplicado um limiar sobre a imagem filtrada normalizada para delinear a região de interesse (ROI), assim, caso o valor do pixel seja maior que o limiar, o mesmo pertence à ROI (Figura 4.6(f)), como mostrado abaixo:

$$ROI(i, j) = \begin{cases} verdadeiro, & se F(i, j) \geq threshold \\ falso, & se F(i, j) < limiar \end{cases} \quad (4.5)$$


O limiar foi definido em 6,0, determinado por um conjunto de treinamento utilizando 80 imagens de impressões digitais. Este limiar foi então aplicado no conjunto de teste com 800 imagens.

**Filtro de Suavização.** Após esta etapa, é aplicado o filtro da mediana para remover ruídos e conectar cristas e vales em uma única região. O tamanho da máscara de mediana foi definido em 5x5. Depois de ser realizada uma avaliação empírica, notou-se que máscaras maiores removiam regiões importantes da imagem de impressão digital, enquanto máscaras menores deixavam uma quantidade significativa de ruído (Figura 4.6(g)).

**Maior Região Branca.** Se a imagem de saída resultante das etapas anteriores possuir mais de uma região que não estão conectadas, a maior região branca é escolhida e as outras são descartadas (Figura 4.6(h)).

**Limpar segmentação e Envoltório Convexo (*Convex Hull*).** Por fim, se existem espaços presentes na região interna da imagem resultante, os mesmos são preenchidos (Figura.4.6(i)) e para finalizar é aplicado o envoltório convexo (*Convex Hull*) para preencher os últimos espaços entre as bordas, tornando assim a ROI final (Figura 4.6(j)). A Figura 4.6 mostra todas as etapas do algoritmo proposto. A área branca indica a região de interesse da impressão digital.

Figura 4.6: Todos os passos do método proposto. (a) Impressão digital de entrada, (b) operações com o histograma, (c) imagem combinada, (d) imagem de homogeneidade, (e) imagem filtrada, (f) binarização, (g) filtro de suavização, (h) maior região branca, (i) limpeza da imagem e (j) envoltório convexo.




Conforme foi mencionado no início do capítulo, existem dois conceitos distintos para a segmentação de impressões digitais. O método mostrado acima com todas as etapas descritas se encaixa no conceito de segmentação em *background* e *foreground*, e foi utilizado para avaliar a segmentação através do método de comparação criado por Thai et al. (2016) e apresentado na próxima subseção. Contudo, para a melhoria das taxas de erro na identificação

de indivíduos foi utilizado o conceito de ROI que retira as regiões irrecuperáveis da imagem, dessa forma foi utilizada a imagem resultante mostrada na Figura 4.6(i), sem a retirada dos espaços contidos na imagem e a utilização do envoltório convexo para preencher as bordas.

A Figura 4.7 mostra a diferença entre os dois conceitos mencionados. Tendo a Figura 4.7(a) como uma imagem de entrada de baixa qualidade com algumas regiões irrecuperáveis, são extraídas as duas regiões de interesse diferentes. A Figura 4.7(b) baseia-se no conceito puro de segmentação, onde a imagem é separada em *background* e *foreground*. Na Figura 4.7(c) o método de segmentação exclui as regiões de baixa qualidade, o que posteriormente irá resultar em uma menor quantidade de falsas minúcias.

Figura 4.7: Imagem de impressão digital segmentada de duas formas utilizando diferentes conceitos



### 4.3.2 Validação do método de segmentação

As bases de dados de imagens de impressões digitais utilizadas para avaliar o método proposto foram as bases de dados do FVC2000, 2002 e 2004 (Cappelli et al., 2007). Cada base de dados possui  $l$  dedos diferentes (largura) e  $p$  amostras por dedo (profundidade), além

disso, existem dois conjuntos diferentes por base de dados, os conjuntos A e B. As características das bases de dados escolhidas são mostradas na Tabela 4.1.

Tabela 4.1: Características das Bases de Dados

FVC	BD	Sensor	Dimensões Imagem	Conjunto A( $l \cdot p$ )	Conjunto B( $l \cdot p$ )	Resolução
2000	1	Ótico	300 x 300	100 x 8	10 x 8	500 dpi
	2	Capacitivo	256 x 364	100 x 8	10 x 8	500 dpi
	3	Ótico	448 x 478	100 x 8	10 x 8	500 dpi
	4	Sintético	240 x 320	100 x 8	10 x 8	Próximo a 500 dpi
2002	1	Ótico	288 x 384	100 x 8	10 x 8	500 dpi
	2	Ótico	296 x 560	100 x 8	10 x 8	569 dpi
	3	Capacitivo	300 x 300	100 x 8	10 x 8	500 dpi
	4	Sintético	288 x 384	100 x 8	10 x 8	Próximo a 500 dpi
2004	1	Ótico	640 x 480	100 x 8	10 x 8	500 dpi
	2	Ótico	328 x 364	100 x 8	10 x 8	500 dpi
	3	Térmico	300 x 480	100 x 8	10 x 8	512 dpi
	4	Sintético	288 x 384	100 x 8	10 x 8	Próximo a 500 dpi

As bases de dados contendo imagens de impressões digitais reais foram obtidas através de diferentes sensores e possuem diferentes propriedades. A qualidade da imagem varia entre imagens de boa qualidade (especialmente as bases FVC2000 DB1 e DB2) e imagens de baixa qualidade que são conseqüentemente mais difíceis de processar (as bases de dados do FVC2004 e FVC2000 DB3).

Para cada base de dados foi utilizado o Conjunto B de imagens para treinar os parâmetros e o Conjunto A para testar o algoritmo. O conjunto de treinamento possui 80 imagens de 10 dedos distintos (8 amostras por dedo). Como pode ser observado na Tabela 4.1, cada base de dados contém 110 dedos com 8 amostras por dedo. No total foram utilizadas 10560 imagens de impressão digital. Thai et al. (2016) realizaram segmentações manuais em todas as 10560 imagens, criando um gabarito para poder avaliar o seu método de segmentação. Eles também desenvolveram um método para avaliar cada algoritmo de segmentação e assim, comparar com os algoritmos de segmentação mais citados na literatura.

O método de avaliação criado consiste em uma comparação entre a imagem segmentada automaticamente e a imagem segmentada manualmente como gabarito, retornando um valor de erro que é descrito na Equação 2.4. Dessa forma, buscando avaliar o método proposto


neste trabalho, foi utilizada a métrica de comparação de Thai et al. (2016). Além disso, devido à algumas inconsistências no método de comparação de Thai et al. (2016) também foi utilizado o método de comparação do índice de Jaccard.

Existem basicamente duas razões para a escolha dessas duas métricas distintas de comparação. Primeiramente, o método proposto por Thai et al. (2016) é utilizado no trabalho dos mesmos para comparar 5 algoritmos bastante conhecidos na literatura e também utilizado por Thai e Gottschlich (2016), que atualmente é o algoritmo do estado da arte em segmentação de impressões digitais, dessa forma usamos esse método de comparação para avaliar o algoritmo de segmentação proposto neste trabalho em relação a esses outros estudos. Todavia, a métrica desenvolvida por Thai et al. (2016) não é muito popular no meio científico, além de possuir um problema lógico. Se a região da impressão digital é muito pequena em relação à imagem completa, incluindo o *background*, como pode ser observado na base de dados FVC2004 DB1, o erro da diferença entre a imagem segmentada manualmente e a imagem segmentada pelos algoritmos é muito pequeno na maioria das vezes. Já para imagens onde a região da impressão digital preenche quase a imagem por completo, como as imagens da base de dados FVC2000 DB2, o erro obtido é muito maior em relação ao primeiro caso.

Na Figura 4.8 é possível ver a diferença entre imagens com regiões pequenas e grandes de impressão digital, quando comparadas com a imagem inteira. A Figura 4.8(a) é uma imagem de impressão digital 53\_2.bmp da base de dados FVC2004 DB1, a Figura 4.8(b) é a imagem segmentada manualmente por Thai et al. (2016), a Figura 4.8(c) é a imagem segmentada automaticamente pelo método de segmentação desenvolvido neste trabalho e a Figura 4.8(d) é a imagem de saída resultante do método de comparação de Thai et al. (2016), usando as Figuras 4.8(b,c) como imagens de entrada. A região branca é a interseção entre as duas imagens de entrada. O erro obtido nesta imagem foi de 0,55%.

Na Figura 4.8e foi realizado um recorte buscando reduzir a área de *background* e provar a hipótese levantada. A imagem resultante (Figura 4.8(h)) obteve um erro de 2,68%, que é relativamente maior comparado ao erro da Figura 4.8(d), mesmo sendo as mesmas imagens, tirando a operação de recorte. Assim, optou-se por também utilizar o método de Jaccard para avaliar o algoritmo proposto, uma vez que o mesmo já é mais aceito e confiável.

Figura 4.8: Diferença nos erros entre uma mesma imagem com apenas um recorte na região de *background*. (a) Imagem de entrada de impressão digital, (e) imagem de impressão digital recortada, (b,f) imagem gabarito segmentada manualmente, (c,g) método de segmentação proposto no presente trabalho, (d,h) imagem resultante da métrica de comparação de Thai, Huckemann e Gottschlich (2016). (A região branca é a região de interseção).



### 4.3.3 Seleção dos Parâmetros

Buscando selecionar os melhores parâmetros que reduzem o erro de similaridade entre as imagens segmentadas manualmente e as imagens segmentadas pelo método proposto, foi usado o conjunto de treinamento de 80 imagens para cada base de dados. A escolha dos parâmetros para cada base de dados é importante, uma vez que as nove bases de dados que consistiam em impressões digitais reais foram adquiridas usando nove sensores diferentes que possuíam características específicas para cada um deles (Thai e Gottschlich, 2016). A seleção de parâmetros para os métodos FDB (Thai et al., 2016), GFB (Shen et al., 2001), HCR (Wu et al., 2007), MVC (Bazen e Gerez, 2001) e STFT (Chikkerur et al., 2007) é discutida em Thai et al. (2016).

A Tabela 4.2 mostra os parâmetros utilizados no algoritmo de segmentação com uma breve descrição de cada um deles.

Tabela 4.2: Parâmetros utilizados no método proposto.

<b>Parâmetros</b>	<b>Descrição</b>
$H_e$	Tamanho do bloco da expansão de histograma
$H_q$	Tamanho do bloco da equalização de histograma
$l$	Limiar da imagem filtrada
$H_o$	Tamanho da máscara de homogeneidade
$n_f$	Número de frequências de Gabor
$n_\sigma$	Número de orientações de Gabor
$g$	Tamanho da máscara de Gabor
$m$	Tamanho do bloco da mediana

Existem três parâmetros que possuem uma grande relevância no algoritmo:  $H_e$ ,  $H_q$  e  $l$ . Eles foram definidos usando o banco de treinamento e aplicados sobre o banco de testes de cada base de dados. Os seus valores são mostrados na Tabela 4.3. Os parâmetros restantes foram definidos manualmente para todas as bases de dados depois de testes empíricos e os seus valores foram os seguintes:  $H_o = 19$ ,  $n_f = 3(6, 8, 10)$ ,  $n_\sigma = 8$ ,  $g = 19$ ,  $m = 5$ .

Tabela 4.3: Visão geral sobre os valores dos parâmetros mais relevantes definidos no conjunto de treinamento.

	<b>FVC</b>	<b>BD</b>	$H_e$	$H_q$	$l$
2000	1	0	25	5,5	
	2	10	25	6,5	
	3	5	25	5,5	
	4	5	20	3,0	
2002	1	0	20	5,5	
	2	5	25	5,5	
	3	10	25	8,0	
	4	10	50	2,5	
2004	1	0	25	5,0	
	2	5	25	6,0	
	3	0	20	9,5	
	4	5	20	4,5	

#### 4.4 Realce da impressão digital (*Enhancement*)

O método de realce desenvolvido neste trabalho é chamado de Biopass *Extraction* e é baseado no trabalho desenvolvido por Turroni et al. (2012), que utiliza filtragem iterativa por filtros de gabor, e pode ser dividido em 5 etapas principais: i) convolução com filtros de gabor, ii) combinação dos melhores resultados da filtragem de gabor, iii) imagem de homogeneidade, iv) seleção dos pixels candidatos, v) realce dos pixels candidatos.

Inicialmente é definido um banco de filtros de gabor  $G = \{g_{i,j}(x,y) | i = 1..n_o, j = 1..n_f\}$  em que  $n_o$  é o número de orientações  $\{\theta_i | i = 1..n_o\}$  e  $n_f$  é o número de frequências  $\{f_j | j = 1..n_f\}$ . Foram definidos empiricamente  $n_o = 8$  e  $n_f = 3$  (8, 3), resultando em  $8 * 3 = 24$  máscaras de gabor.

A imagem de entrada  $I = \{i_{x,y} | x = 1..w, y = 1..h\}$ , em que  $w$  e  $h$  são a largura e altura, respectivamente, é convoluída com cada uma das máscaras existentes no banco. Um conjunto  $V$  com as 24 imagens resultantes da convolução é criado para definir a imagem

combinada, onde cada pixel é determinado pela melhor resposta do gabor dentre os pixels de mesma posição das imagens resultantes. Os pixels que estão em regiões de crista respondem negativamente e pixels em regiões de vale respondem positivamente, quanto maior o módulo da resposta (positiva ou negativa), maior será a confiança no pixel escolhido da imagem combinada. A Equação 4.6 mostra o valor do pixel em determinada posição da imagem.

$$p(x, y) = \max(|V_1(x, y)|, |V_2(x, y)|, \dots, |V_{24}(x, y)|) \quad (4.6)$$

Posteriormente é criada uma imagem de homogeneidade  $H = \{h_{x,y} | x = 1..w, y = 1..h\}$  que tem como objetivo retirar descontinuidades da imagem de entrada, visto que mudanças repentinas na orientação e frequência em regiões pequenas não devem existir, exceto em regiões de singularidade. Verifica-se para cada pixel, a orientação e frequência dos pixels de sua vizinhança, através de uma janela de 9x9 pixels. Para regiões bem definidas, onde a fluidez de cristas e vales é evidente, a imagem de homogeneidade terá valores altos, e para regiões ruins, que possuam uma alta descontinuidade, os pixels da imagem de homogeneidade terão valores pequenos.

Após a etapa da imagem de homogeneidade, o algoritmo escolhe os pixels que serão realçados utilizando um critério de classificação. A ideia é selecionar uma porcentagem de pixels de boa qualidade, ou seja, pixels que obtiveram uma boa resposta (positiva ou negativa) para a filtragem e que possivelmente pertencem a regiões de alta homogeneidade. É criada uma imagem filtrada  $F = \{c_{x,y} | x = 1..w, y = 1..h\}$  a partir da multiplicação da imagem combinada e da imagem de homogeneidade, selecionando os melhores pixels (Equação 4.7).

$$F_{x,y} = c_{x,y} \cdot h_{x,y} \cdot r_{x,y} \quad (4.7)$$

Em que  $R = \{r_{x,y} | x = 1..w, y = 1..h\}$  é uma matriz de seleção a qual  $0 < r_{x,y} \leq 1$ . A matriz  $R$  controla a seleção dos pixels candidatos nas sucessivas iterações; todos os valores de  $r_{x,y}$  são iniciados com 1, mas quando um pixel  $I_{x,y}$  é selecionado, o pixel correspondente em  $r_{x,y}$  é multiplicado por uma constante de decaimento  $0 \leq \rho < 1$ , com o intuito de inibir uma nova seleção desse pixel nas próximas iterações.

O algoritmo ordena os pixels da imagem  $F$  e escolhe os pixels com maior resposta negativa e os pixels com maior resposta positiva através de um valor percentual  $\gamma$ , e os coloca

em dois conjuntos A e B correspondendo às cristas e vales, respectivamente. Os conjuntos podem ser definidos pelas seguintes equações.

$$A = \{I_{x,y} | \text{rank}(f_{x,y}) \leq \gamma \cdot |F|\} \quad (4.8)$$

$$B = \{I_{x,y} | \text{rank}(f_{x,y}) \geq (1 - \gamma) \cdot |F|\} \quad (4.9)$$

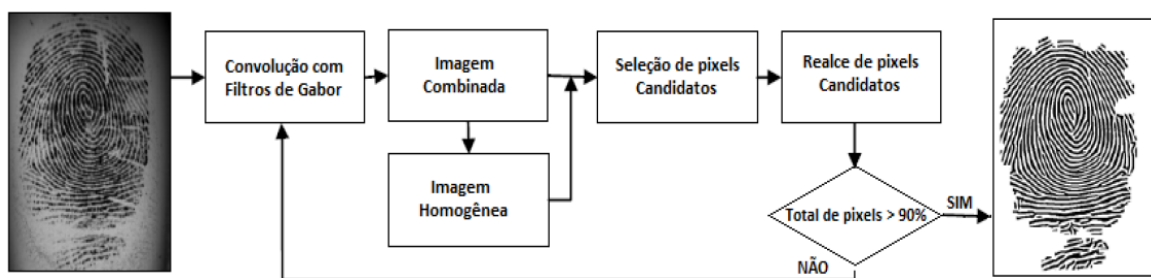
Os pixels contidos nos conjuntos A e B serão realçados da seguinte maneira:

$$\Delta_{x,y} = \begin{cases} 0 & , \text{ se } I_{x,y} \in A \\ 255 & , \text{ se } I_{x,y} \in B \end{cases} \quad (4.10)$$

$$I_{x,y} = I_{x,y} \cdot (1 - \epsilon) + \Delta_{x,y} \cdot \epsilon \quad (4.11)$$

Em que  $0 < \epsilon \leq 1$  controla a intensidade do realce. O algoritmo utiliza  $\epsilon = 0,7$ . O algoritmo continua realizando iterações até que um critério de convergência seja satisfeito: o número máximo de iterações é alcançado, ou não existem mais regiões de baixa qualidade na imagem, ou uma porcentagem dos pixels totais da imagem já sofreram realce. A Figura 4.9 mostra as etapas realizadas no método de *enhancement* criado por Turrone et al. (2012).

Figura 4.9: Etapas do processo de realce de imagens de impressões digitais realizado por Turrone, Cappelli e Maltoni (2012).



A Figura 4.10 mostra o resultado do processo aplicado pelo método de Turrone et al. (2012) sobre uma imagem de baixa qualidade.

Figura 4.10: Evolução de uma imagem ruidosa de impressão digital durante o processo iterativo de *enhancement*.




O método de *enhancement* implementado por Turrone et al. (2012), mostrou-se bastante eficiente, contudo, os mesmos citaram alguns problemas além de outros que foram detectados após sua implementação:

- A região processada inclui pixels fora da área de impressão digital dependendo da região de interesse definida;
- O processamento é executado em áreas de impressão digital que são irrecuperáveis, criando falsas minúcias;
- O tempo de processamento leva cerca de 10 segundos para extrair características de apenas uma imagem de impressão digital.

Para corrigir o problema das regiões irrecuperáveis e a inclusão de pixels fora da área da impressão digital, foi utilizada a imagem de segmentação resultante dos processos anteriores, utilizando o conceito de ROI de retirar as regiões com baixa qualidade. Com isso, o algoritmo de *enhancement* foi aplicado apenas nos pixels provenientes da imagem de entrada que faziam parte da ROI (Região Branca). A Figura 4.11 mostra a diferença que a imagem segmentada representa para o resultado final da extração de minúcias. Na Figura 4.11(b) foi utilizada uma ROI completa apenas diferenciando *background* e *foreground* resultando em uma imagem final (Figura 4.11(c)) com várias minúcias falsas (círculos azuis) e, conseqüentemente aumentando as taxas de erro nos sistemas de identificação. Na Figura 4.11(d) o método de segmentação exclui as regiões de baixa qualidade, obtendo uma menor quantidade de falsas minúcias.

Figura 4.11: Realce de impressões digitais através das diferentes abordagens de segmentação.



Outra modificação realizada foi na criação das máscaras de Gabor. Foi utilizado o mesmo conceito citado na seção sobre o método de segmentação, que utiliza máscaras de Gabor adaptativas, que têm o desvio padrão definido a partir da frequência, o que traz melhorias ao algoritmo. O processo está melhor descrito na Seção 4.3.1.

Além disso, foi realizada uma outra modificação de grande importância, que trata do valor percentual  $\gamma$  utilizado por Turrone et al. (2012). O mesmo utiliza um valor fixo o qual a cada iteração seleciona os  $\gamma\%$  melhores pixels para serem realçados. Isso implica em uma grande quantidade de iterações para finalizar o processo, caso o valor de  $\gamma$  seja muito pequeno, e um realce muito agressivo, provavelmente com erros, caso o valor de  $\gamma$  seja muito elevado. Dessa forma, foi utilizado um valor variável de acordo com a iteração. Uma vez que antes da primeira iteração a imagem de entrada possui uma qualidade mais baixa e sem nenhum pixel realçado, inicia-se  $\gamma$  com um valor fixo, e após cada iteração, o mesmo é incrementado por um valor referente à iteração a qual pertence, conforme descrito na equação abaixo.

$$\gamma = \gamma + (\beta \cdot It) \quad (4.12)$$

Onde  $\beta$  é uma constante multiplicativa definida como 0,05 e  $It$  é o índice da iteração,

iniciando pela iteração de número zero. O valor inicial de  $\gamma$  foi definido como 0,15, significando que os 15% melhores pixels de cada extremidade são realçados na primeira iteração. Na segunda iteração ( $It = 1$ ) o valor de  $\gamma$  será de 0,20 e assim sucessivamente até chegar na condição de parada, definida pelo valor de  $\gamma$  igual a 0,40.

Dessa forma, nas iterações posteriores, o método de realce fica mais agressivo já que as imagens resultantes dessas novas iterações possuem uma melhor qualidade, resultando ao fim em uma menor quantidade de iterações necessárias para realçar a imagem por completo.

Para trabalhos futuros é possível utilizar a qualidade global da imagem para definir o valor inicial de  $\gamma$  e  $\beta$ . Imagens de boa qualidade necessitam de poucas iterações para serem realçadas e podem ter valores de  $\gamma$  e  $\beta$  mais altos, enquanto que imagens de baixa qualidade precisam de mais iterações e valores mais baixos.

## 4.5 Afinamento, localização e filtragem de minúcias

Após a etapa de realce, o algoritmo realiza a etapa de extração de minúcias, que é dividida nas etapas de binarização, suavização, afinamento e remoção de falsas minúcias. Os métodos utilizados nessas etapas são consolidados na literatura e aceitos como o estado da arte. Dessa forma, a medida que não são etapas críticas e que não necessitam tamanha atenção como as etapas de segmentação e realce, optou-se por apenas utilizar as técnicas já consolidadas, que serão brevemente descritas abaixo:


- Binarização local – A imagem resultante da filtragem por Gabor é binarizada utilizando um limiar. Caso o pixel esteja abaixo do limiar, ele é convertido para preto, caso contrário, o pixel será branco (Figura 4.12).

Figura 4.12: Binarização local



- Filtro da mediana sobre imagem binarizada – É aplicado um filtro da mediana para retirar o ruído proveniente das etapas anteriores. A máscara utilizada é de 3x3 pixels (Figura 4.13).

Figura 4.13: Aplicação do filtro da mediana local



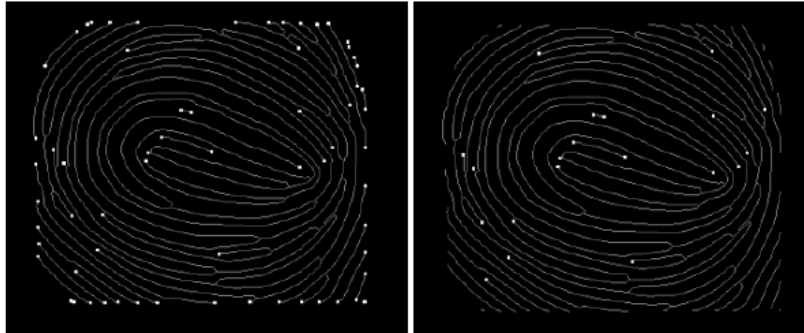
- Criação do esqueleto e extração das características – É realizado um afinamento sobre a imagem final, transformando as cristas em linhas de espessura de apenas 1 pixel para facilitar a extração das minúcias (Figura 4.14).

Figura 4.14: Afinamento das cristas



- Remoção de falsas minúcias – Algumas restrições são aplicadas para retirar minúcias falsas, como minúcias muito próximas das bordas, terminações incorretas de cristas e algumas ramificações (Figura 4.15).

Figura 4.15: Remoção de falsas minúcias



## 4.6 Métrica de Avaliação Geral

A métrica utilizada para avaliar o sistema completo de extração desenvolvido neste trabalho, que é composto pelas seções anteriores, é a taxa de erro igual (*Equal Error Rate* (EER)). A escolha desta métrica se dá pelo fato de ser bastante utilizada em sistemas de identificação, além de ser a principal métrica de avaliação utilizada nas principais competições internacionais de identificação de indivíduos por impressões digitais, como a FVC.

As imagens utilizadas para medir a eficácia do método são provenientes de 6 bancos utilizados em edições anteriores do FVC. Foram utilizados os bancos DB3 da edição 2000, DB1 da edição 2002, DB1, DB2 e DB3 da edição 2004 e DB2 da edição 2006. As imagens dos bancos estão em escala de cinza de 256 níveis no formato BMP capturadas por sensores óticos e com resolução de 500 DPI, com exceção dos bancos DB3 FVC2004 e DB2 FVC2006 que possuem resolução de 512 e 569 DPI, respectivamente. A seleção de tais bancos foi feita para gerar uma maior heterogeneidade, uma vez que possuem um conjunto de amostras bastante diversificado tanto em tamanho, qualidade e resolução. Todos os bancos se assemelham a um banco de dados comercial. No total foram utilizadas 5680 amostras distribuídas entre os bancos. Os 5 primeiros citados anteriormente possuem 800 amostras, sendo 8 amostras por dedo, para 100 dedos. O banco FVC2006 por sua vez possui um total de 1680 amostras, sendo 12 amostras por dedo, para 140 dedos. Detalhes dos bancos são mostrados na Tabela 4.4.

Tabela 4.4: Descrição dos bancos utilizados

FVC	DB	Sensor	Dimensões Imagem	Amostras	Indivíduos	Resolução
2000	3	Ótico	448 x 478	800	100	500 dpi
2002	1	Ótico	388 x 374	800	100	500 dpi
2004	1	Ótico	640 x 480	800	100	500 dpi
2004	2	Ótico	328 x 364	800	100	500 dpi
2004	3	Térmico	300 x 480	800	100	512 dpi
2006	2	Ótico	400 x 560	1680	140	569 dpi

Além disso foi realizada uma análise comparativa entre este trabalho e alguns algoritmos de extração de características desenvolvidos por diferentes fontes. O primeiro algoritmo comparado é o de extração do SourceAFIS, que é um algoritmo de código aberto e está disponível no site do projeto Source Afis (Važan, 2009) e conta com o código de extração de minúcias e de *Matching* escritos nas linguagens de programação C# e Java. A versão em Java ainda está em desenvolvimento contando com apenas parte do código, incluindo o algoritmo de extração.

O segundo algoritmo é o algoritmo de extração da Neurotechnology, empresa situada na Lituânia e que é líder mundial nas maiores competições de identificação como a FVC e o MINEX, obtendo as menores taxas de erros e sendo conhecida internacionalmente. Como a Neurotechnology é uma empresa privada, não é possível ter acesso ao código, sendo disponibilizadas apenas algumas bibliotecas de vínculo dinâmico (*Dynamic-link library* (DLLs)) para executar o algoritmo, além disso, a empresa não possui o interesse em disponibilizar artigos científicos por motivos comerciais. Também foi utilizado o algoritmo que foi desenvolvido no trabalho de Turroni et al. (2012), o qual é base para o trabalho desenvolvido nesta dissertação. Os experimentos de casamento serão conduzidos utilizando o protocolo do FVC (BioLab, 2006).

Os algoritmos propostos foram executados sobre cada banco individualmente e as referências para os *templates* extraídos foram armazenadas em um banco de dados auxiliar (SQLite). Após essa etapa foi executado o algoritmo de *Matching* desenvolvido pelo Biolab (Cappelli et al., 2010), conhecido como *Minutia cylinder-code* (MCC), para todos os *templates* previamente extraídos. Ao utilizar um único algoritmo de *Matching* para cada um dos

algoritmos de extração em estudo, há uma garantia de que as variações nos resultados e taxas de erros serão provenientes apenas dos algoritmos de extração, podendo ser realizada uma comparação justa entre eles.

Após a realização do casamento de minúcias, o resultado final da comparação dos pares de digitais é persistido junto com o escore resultante. Com a análise desses dados é possível determinar as taxas de FAR e FRR, e determinar o melhor limiar baseado no EER.

Para cada banco de imagens foi realizada um tipo de comparação entre as amostras do mesmo dedo, onde uma amostra é comparada com as demais amostras deste dedo; e uma comparação entre as amostras equivalentes de dedos diferentes. A primeira amostra do primeiro dedo é comparada com as primeiras amostras dos demais dedos.

O primeiro tipo de comparação tem o objetivo de determinar a FRR, uma vez que as amostras pertencem ao mesmo dedo e caso não sejam casadas corretamente indicará uma falsa rejeição. Para os bancos com 800 amostras, onde existem 10 amostras de cada um dos 100 dedos, a primeira etapa de comparações realiza  $((10*9) / 2) * 100 = 4.500$  comparações. Para o banco com 1680 amostras, serão realizadas  $((12 * 11) / 2) * 140 = 9.240$  comparações.

A segunda etapa de comparações busca determinar a FAR, uma vez que testa as amostras equivalentes de dedos diferentes. Nesta etapa, para os bancos de 800 amostras, serão realizadas  $((100*99) / 2) = 4.950$  comparações. Para o banco FVC2006 serão realizadas  $((140*139) / 2) = 9.730$  comparações. Finalizando, foram realizadas para os primeiros bancos, 9.450 comparações em cada um e para o último banco, 18.970 comparações.

## 4.7 Avaliação do tempo de processamento

Além das métricas anteriores, também foram avaliados os tempos de processamento de três algoritmos, excluindo o tempo para carregamento das imagens e o tempo para inserção dos *templates* no banco de dados, com isso é possível obter o tempo de processamento de forma mais confiável. Os algoritmos selecionados para a comparação foram o SourceAfis e o algoritmo desenvolvido pela Neurotechnology, uma vez que foi possível ter acesso à implementação e ao executável dos mesmos, respectivamente.

Quanto ao método desenvolvido por Turrone et al. (2012) não foi possível ter acesso ao código ou a algum arquivo executável, contudo, sabe-se que de acordo com os próprios

autores, o tempo médio de processamento é de 10 segundos, sendo um grande empecilho para a utilização do algoritmo em ambientes reais. É preciso ressaltar que a comparação com o algoritmo de Turroni et al. (2012) não vai poder ser realizada de forma confiável, uma vez que não é possível saber qual a configuração da máquina utilizada pelos autores para a realização dos testes de tempo de processamento.

# Capítulo 5

## Resultados e Discussões

Neste capítulo, são apresentados os principais resultados alcançados pelos métodos descritos na metodologia, realizando comparações com os principais algoritmos, considerados o estado da arte em suas devidas áreas. Além disso, são apresentadas as discussões sobre os resultados.

Os resultados estão divididos em três etapas: A primeira se refere aos encontrados na avaliação da segmentação da impressão digital. Em seguida, são apresentados valores obtidos através da avaliação do processo completo de extração de características e *matching* de impressões digitais, utilizando como base a competição internacional FVC. Por fim, são descritos os resultados da extração de características utilizando bases de dados locais, comparando diversos algoritmos de extração e utilizando um algoritmo único de comparação de *templates* em comum, com o intuito de realizar a separação entre extração e *matching*, uma vez que na FVC o algoritmo enviado é composto por essas duas etapas, não sendo possível a identificação da eficácia individual do algoritmo de extração.

### 5.1 Resultados da avaliação dos métodos de segmentação de impressões digitais

O método de avaliação proposto por Thai et al. (2016) compara os cinco algoritmos de segmentação mais citados na literatura. Além disso, a pesquisa realizada por Thai e Gottschlich (2016) também compara o seu algoritmo com os outros previamente mencionados. Assim,

para avaliar o método proposto, o algoritmo de segmentação desenvolvido neste trabalho foi comparado com esses algoritmos considerados o estado da arte na segmentação de impressões digitais.

A Tabela 5.1 mostra todos os resultados obtidos pelos algoritmos utilizando a métrica de comparação de Thai et al. (2016) descrita na Seção 2.11. Os algoritmos comparados são: o método de respostas baseadas em um banco de filtros de Gabor (*Gabor Filter Bank*) (GFB) (Shen et al., 2001); o método baseado nas respostas das bordas de Harris e Stephens (1988) (*Harris Corner Response*) (HCR) desenvolvido por Wu et al. (2007); o método de (Bazen e Gerez, 2001), que utiliza média, variância e coerência dos pixels como características (*Gray-level Mean, Variance and gradient Coherence*) (MVC); o método de Chikkerur et al. (2007), que utiliza transformadas de Fourier de curta duração (*Short Time Fourier Transforms*) (STFT); além dos métodos de segmentação desenvolvidos por Thai et al. (2016) (*Factorized Directional Bandpass*) (FDB), Thai e Gottschlich (2016) (*Global variational method for fingerprint segmentation by three-part decomposition*) (G3PD) e o método desenvolvido neste trabalho, chamado de *Biopass Segmentation* (BPS).

Tabela 5.1: Comparação dos algoritmos utilizando o método de comparação proposto por Thai, Huckemann e Gottschlich (2016). Em negrito estão as menores taxas de erro por base de dados.

FVC	DB	GFB	HCR	MVC	STFT	FDB	G3PD	BPS
2000	1	13,26	11,15	10,01	16,70	5,51	5,69	<b>4,49</b>
	2	10,27	6,25	12,31	8,88	<b>3,55</b>	4,10	4,00
	3	10,63	7,80	7,45	6,44	2,86	2,68	<b>2,33</b>
	4	5,17	3,23	9,74	7,19	2,31	2,06	<b>2,03</b>
2002	1	5,07	3,71	4,59	5,49	2,39	1,72	<b>1,59</b>
	2	7,76	5,72	4,32	6,27	2,91	2,83	<b>2,67</b>
	3	9,60	4,71	5,29	5,13	3,35	3,27	<b>3,16</b>
	4	7,67	6,85	6,12	7,70	4,49	3,63	<b>3,61</b>
2004	1	5,00	2,26	2,22	2,65	1,40	<b>0,88</b>	1,12
	2	11,18	7,54	8,06	9,89	4,90	4,62	<b>4,61</b>
	3	8,37	4,96	3,42	9,35	3,14	2,77	<b>2,60</b>
	4	5,96	5,15	4,58	5,18	2,79	2,53	<b>2,49</b>
Avg.		8,33	5,78	6,51	7,57	3,30	3,06	<b>2,89</b>

Como mostrado na Tabela 5.1, o método desenvolvido, denominado BPS (*BioPass Segmentation*) obteve melhores resultados em 10 das 12 bases de dados testadas, em comparação com os outros seis algoritmos listados.


Comparando com o algoritmo do estado da arte (Thai e Gottschlich, 2016), o método BPS obteve uma melhoria média de 5,6%, e alcançou taxas de erros menores em 11 das 12 bases de dados, obtendo um resultado pior apenas na base de dados FVC2004 DB1.

Um dos maiores problemas encontrados no algoritmo ocorreu em imagens com duas ou mais regiões desconectadas como é possível observar na imagem 85\_3.bmp do FVC2004-3 (Figura 5.1). Uma das etapas descritas do algoritmo é a determinação da maior região branca,

dessa forma, o mesmo exclui outras regiões menores da imagem que não estão conectadas com a região maior.

A Figura 5.1 mostra como esse problema produz uma alta taxa de erro quando são comparadas as imagens segmentadas e a imagem gabarito (segmentada manualmente). O erro encontrado no primeiro cenário utilizando o filtro da maior região branca foi de 8,22%, uma vez que toda a região inferior da imagem foi excluída. Para solucionar esse problema é necessário selecionar mais de uma região, utilizando um limiar que define o tamanho mínimo para que uma região possa ser selecionada e não utilizar apenas a maior região. Nesse caso, o erro encontrado foi de 2,54%, representando uma melhora de 69,1%.

Figura 5.1: Diferentes taxas de erro entre as imagens segmentadas pelo algoritmo e a imagem segmentada manualmente, utilizando o filtro da maior região branca (8.22%) e utilizando todas as regiões com tamanhos maiores que um limiar (2.54%).



Neste trabalho também foi utilizada a métrica de comparação de Jaccard, com o intuito de obter uma métrica mais confiável e mais utilizada na área de imagens. As taxas de erro de cada base dados podem ser observadas na Tabela 5.2, comparando os resultados obtidos pelo método proposto (BPS) utilizando as duas métricas de comparação (Coeficiente de Jaccard e a métrica desenvolvida por Thai et al. (2016)).

A taxa de erro média entre todas as bases de dados utilizando a métrica de comparação de Jaccard foi mais alta do que a encontrada pela métrica de comparação de Thai et al. (2016), no entanto, como mencionado anteriormente, a métrica de Jaccard é mais confiável, uma vez que o tamanho da imagem em relação à impressão digital é irrelevante para essa métrica, diferentemente do que acontece na métrica de comparação de Thai et al. (2016).

Tabela 5.2: Taxas de erros obtidas pelo *BioPass Segmentation*, utilizando as duas técnicas de comparação citadas (Coeficiente de Jaccard e a métrica desenvolvida por Thai, Huckemann e Gottschlich (2016)).

	DB	BPS (Jaccard)	BPS(Thai et al. (2016))
2000	1	5,38	4,49
	2	5,21	4,00
	3	3,90	2,33
	4	3,16	2,03
2002	1	3,16	1,59
	2	3,93	2,67
	3	5,63	3,16
	4	6,04	3,61
2004	1	4,12	1,12
	2	7,44	4,61
	3	4,01	2,60
	4	4,05	2,49
Avg.		5,00	2,89

O tempo de processamento do algoritmo de segmentação desenvolvido também é outra questão a ser discutida, se tornando mais um aspecto a ser melhorado. O tempo médio para a extração da Região de interesse foi em torno de 0,4 segundos, com um desvio padrão de 0,08 segundos, o que pode ser considerado um tempo de processamento elevado. As principais razões para esse tempo elevado são as sucessivas convoluções com os filtros de Gabor realizadas entre as máscaras de Gabor e a imagem de impressão digital.

## 5.2 Resultados da competição FVC

O método de extração desenvolvido neste trabalho foi avaliado através da competição internacional FV-OnGoing na modalidade comparação 1-1 que avalia o sistema completo de identificação com as etapas de extração e casamento presentes. Dessa forma, como não é possível avaliar a etapa de extração separadamente, foi utilizado o algoritmo de casamento de

impressões digitais desenvolvido por pesquisadores do laboratório de visão computacional da UFPB (VisioLab) (Araujo, 2015), criando um AFIS completo com esses dois módulos.

A Tabela 5.3 mostra o desempenho do método proposto, fonte de cor esverdeada, em relação aos demais candidatos de todas as versões do FVC. Observa-se que o método proposto alcançaria a primeira colocação no FVC 2000, banco DB3, que teve um total de 11 participantes; oitava colocação no FVC 2002, banco DB2, que teve um total de 31 participantes; sexta colocação em ambas modalidades do FVC 2004, onde 41 participaram da modalidade no banco DB1 e 42 participaram na modalidade do banco DB2; e décima colocação no FVC 2006, banco DB3 que teve um total de 42 participantes classificados.

Tabela 5.3: Desempenho do método proposto, de cor verde, em relação aos demais candidatos em todas as versões do projeto FVC

Pos/EER	FVC-OnGoing	DB06	DB04-2	DB04-1	DB02	DB00
1	0,02%	0,02%	1,58%	1,97%	0,10%	<b>3,28%</b>
2	0,04%	0,03%	2,59%	2,72%	0,24%	3,64%
3	0,10%	0,10%	2,79%	3,38%	0,25%	4,01%
4	0,11%	0,10%	3,17%	3,62%	0,52%	5,36%
5	0,14%	0,12%	3,23%	3,91%	0,61%	8,29%
6	0,15%	0,12%	<b>3,42%</b>	<b>4,03%</b>	0,63%	11,94%
7	0,17%	0,14%	3,49%	4,10%	0,67%	12,20%
8	0,24%	0,14%	3,56%	4,18%	<b>0,85%</b>	16,32%
9	0,29%	0,19%	3,62%	4,37%	0,98%	17,73%
10	0,41%	<b>0,21%</b>	3,75%	5,54%	1,17%	22,63%
11	0,61%	0,24%	4,01%	5,64%	1,46%	23,18%
12	0,62%	0,25%	4,39%	6,13%	1,63%	47,43%
13	0,71%	0,27%	4,67%	6,49%	1,85%	-
14	<b>0,74%</b>	0,29%	4,83%	7,18%	1,91%	
15	0,76%	0,37%	4,99%	7,47%	2,15%	
16	1,02%	0,47%	5,15%	7,61%	2,36%	-
17	1,03%	0,49%	5,48%	7,65%	2,57%	
18	1,26%	0,51%	5,50%	7,68%	2,70%	
19	1,61%	0,49%	5,54%	8,31%	2,72%	
20	2,31%	0,66%	5,68%	8,41%	3,02%	

Atualmente o algoritmo está na décima quarta posição do projeto FVC-OnGoing com taxa de erro de 0,74%. Nesta competição, que está em vigor desde a última versão do projeto, o banco de dados no qual o algoritmo será executado não é conhecido e o método proposto é o único algoritmo classificado que é de origem brasileira. É preciso mencionar que dos 13 algoritmos que estão mais bem colocados, 9 pertencem a empresas privadas, que não possuem interesse em publicar seus resultados em artigos científicos, além disso, outros 3 são de desenvolvedores independentes e apenas um algoritmo foi desenvolvido por um grupo

de pesquisa acadêmica.

Dessa forma, o algoritmo de extração de características e criação de *template* desenvolvido neste trabalho, juntamente com o algoritmo de *matching* desenvolvido por Araujo (2015) é considerado o melhor algoritmo de reconhecimento de indivíduos por impressão digital do Brasil, e, na área acadêmica, o segundo melhor classificado mundialmente.

### 5.3 Resultados obtidos pela métrica de avaliação geral

Além da avaliação do método de extração realizada pelo FVC, foram realizados testes locais em ambiente controlado, com bases de dados conhecidas, para poder avaliar de forma mais precisa a eficácia do algoritmo de extração desenvolvido neste trabalho, o BioPass *Extraction*, uma vez que nesse tipo de avaliação, foi utilizado um algoritmo de casamento em comum para todos os algoritmos de extração.

A metodologia utilizada para a obtenção destes resultados foi previamente descrita na Seção 4.6. As taxas de EER resultantes da execução de cada algoritmo para as 6 bases de dados são mostradas na Tabelas 5.4. A taxa de EER é obtida através da média entre as taxas de Falsa Aceitação e Falsa Rejeição, definidas por um limiar que encontra o ponto de interseção aproximado entre as curvas de Falsa Aceitação e Falsa Rejeição.


A Tabela 5.4 mostra os valores obtidos de EER para cada uma das 6 bases de dados utilizadas, comparando as taxas de erro dos 4 algoritmos de extração descritos na Seção 4.6, utilizando o algoritmo de casamento desenvolvido por Cappelli et al. (2010). Como não foi possível a obtenção do algoritmo de extração desenvolvido por Turrone et al. (2012), os resultados mostrados na Tabela 5.4 são apenas das três bases de dados que os autores utilizaram no seu trabalho.

Tabela 5.4: EER obtidos utilizando a extração dos algoritmos abaixo em conjunto com o algoritmo de casamento desenvolvido por Cappelli, Ferrara e Maltoni (2010)

DB	Neurotechnology	BioPass <i>Extraction</i>	SourceAfis	MCC
FVC2000_3	3,05%	<b>2,40%</b>	6,74%	-
FVC2002_1	<b>0,61%</b>	0,71%	1,22%	-
FVC2004_1	<b>3,32%</b>	4,22%	6,24%	-
FVC2004_2	<b>4,15%</b>	4,85%	7,40%	5,68%
FVC2004_3	<b>1,82%</b>	2,45%	3,90%	3,17%
FVC2006_2	<b>0,17%</b>	0,38%	0,64%	0,66%
Média	<b>2,18%</b>	2,50%	4,35%	3,17%

Ao analisar os resultados, é possível observar que o algoritmo de extração da Neurotechnology é o mais eficiente em 5 das 6 bases de dados verificadas. Contudo, este algoritmo é considerado o mais eficiente mundialmente, e, pertencendo à uma empresa privada, tem objetivo estritamente comercial, não tendo interesse em divulgar detalhes da implementação. Ainda assim, o algoritmo BioPass *Extraction*, desenvolvido neste trabalho, obteve uma taxa de EER melhor que o algoritmo da Neurotechnology na base de dados FVC2000 DB3, e além disso, obteve no geral a segunda melhor colocação entre os algoritmos comparados. Observa-se que a base de dados FVC2000 DB3, entre as comparadas é a que possui imagens de impressão digital de pior qualidade, como é possível observar na Figura 5.2, com uma grande quantidade de ruído, cortes e cicatrizes, além de ter o fundo difuso, dificultando a separação entre *background* e *foreground*. Assim, é possível afirmar que a segmentação realizada neste trabalho foi fundamental para os resultados obtidos, principalmente para imagens de baixa qualidade.


Figura 5.2: Amostras de impressões digitais de diferentes bases de dados: (a) Imagem 15\_3 da base de dados FVC2000 DB3; (b) Imagem 3\_8 da base de dados FVC2002 DB1; (c) Imagem 37\_5 da base de dados FVC2006 DB2.



Nas bases de dados FVC2004 DB1 e DB2 o BioPass *Extraction* obteve as maiores taxas de erro. Isso deve-se principalmente ao fato das imagens dessas bases de dados possuírem uma frequência maior entre as cristas, diferentemente da base de dados FVC2000 DB3, como é possível observar na Figura 5.3, onde a imagem 17\_4 da base FVC2004 DB1 (Figura 5.3(a)) é comparada com a imagem 15\_8 (Figura 5.3 (b)) da base FVC2000 DB3. Utilizando a mesma escala para as duas imagens, ao realizar um recorte de 50x50 pixels, foram encontrados 7 e 4 cristas, respectivamente.

Assim, máscaras de Gabor com frequências maiores deverão obter melhores respostas para imagens da base FVC2004 DB1, enquanto que para a base FVC2000 DB3, as melhores respostas seriam para as máscaras com frequências mais baixas. Como o algoritmo desenvolvido nessa pesquisa utiliza valores fixos de frequência nas máscaras de Gabor, possivelmente houve um melhor ajuste para a base de dados FVC2000 DB3. Para corrigir este problema é preciso utilizar as melhores frequências para cada imagem individualmente, ao invés de selecionar frequências genéricas como foi realizado.

Figura 5.3: Comparação das frequências de cristas entre imagens de diferentes bases de dados: (a) Imagem 17\_4 da base FVC2004 DB1; (b) Imagem 15\_8 da base FVC2000 DB3



Com relação ao algoritmo de Turrone et al. (2012), que é a base para este trabalho, o BioPass *Extraction* obteve um ganho de 14,6%, 22,7% e 42,4% nas bases FVC2004 DB2, FVC2004 DB3 e FVC2006 DB2, respectivamente, com as modificações realizadas. Além disso, houve uma considerável redução no tempo de processamento de realce da imagem de impressão digital, que segundo o trabalho de Turrone et al. (2012) variava em torno de 10 segundos e no trabalho desenvolvido nesta pesquisa caiu para 1,90 segundos em média, como pode ser observado na Tabela 5.5. Essa diminuição do tempo de processamento deve-se principalmente à redução no número de iterações, e, conseqüentemente uma menor quantidade de convoluções realizadas, já que no processo inteiro as convoluções são as operações mais custosas computacionalmente.

Dessa forma, é possível afirmar que o BioPass *Extraction* obteve sucesso na tentativa de melhorar o método de Turrone et al. (2012), reduzindo algumas de suas falhas e conseqüentemente diminuindo as taxas de erros e o tempo de processamento, e de obter resultados próximos aos melhores algoritmos de instituições privadas.

## 5.4 Avaliação do tempo de processamento

Os tempos de processamento dos algoritmos em estudo podem ser verificados na Tabela 5.5. Foi obtido o tempo médio para a extração do *template* das imagens em cada uma das bases.

O tempo da inserção do *template* no banco de dados auxiliar foi retirado para não haver interferência nos resultados, assim como o tempo para carregamento das imagens.

Tabela 5.5: Comparação do tempo de processamento para extração de características entre algoritmos

DB/Algoritmo	BioPass <i>Extraction</i>	Neurotechnology	SourceAfis
<b>FVC2000 DB3</b>	2,1521 s	0,3075 s	<b>0,2718 s</b>
<b>FVC2002 DB1</b>	1,5401 s	0,1075 s	<b>0,1050 s</b>
<b>FVC2004 DB1</b>	1,6348 s	0,1537 s	<b>0,1431 s</b>
<b>FVC2004 DB2</b>	1,8236 s	<b>0,1125 s</b>	0,1212 s
<b>FVC2004 DB3</b>	2,0372 s	0,2531 s	<b>0,2041 s</b>
<b>FVC2006 DB2</b>	2,2497 s	0,2886 s	<b>0,2239 s</b>
<b>Média</b>	1,9062 s	0,2038 s	<b>0,1781 s</b>

Conforme foi mencionado anteriormente, o tempo de processamento do algoritmo desenvolvido por Turrone et al. (2012) varia em torno de 10 segundos, o que é um grande empecilho para sua utilização em ambientes reais. Na Tabela 5.5 observa-se que o método desenvolvido neste trabalho obteve uma melhoria de 81% na velocidade do algoritmo, com a ressalva de que não é possível saber em qual máquina os autores realizaram os testes de tempo de processamento.

Ao realizar a comparação com os algoritmos SourceAfis e da Neurotechnology é possível notar que o tempo de processamento do algoritmo do Biopass *Extraction* é consideravelmente maior. Isso ocorre pois o algoritmo utiliza filtragem de Gabor de forma iterativa, realizando 24 convoluções em cada iteração, o que, mesmo com todas as melhorias e reduções no número de iterações, ainda apresenta um custo computacional elevado. O SourceAfis obteve os melhores resultados na avaliação do tempo de processamento devido ao seu algoritmo simples e com baixo custo computacional. A Neurotechnology obteve resultados próximos aos do SourceAfis.

Após a realização dos testes e obtenção dos resultados contidos nas seções anteriores, no próximo capítulo serão mostradas algumas considerações finais e perspectivas de trabalhos futuros.

## Capítulo 6

# Considerações finais e trabalhos futuros

Neste trabalho, foram apresentados novos métodos para extração de características a partir de uma imagem de impressão digital. A extração é considerada uma etapa de grande importância, uma vez que juntamente com o *matching*, forma um sistema completo de identificação de indivíduos utilizando a impressão digital. Foram desenvolvidos métodos de segmentação e realce da imagem de impressão digital para auxiliar na extração de atributos a serem inseridos no *template* e posteriormente comparados na etapa de casamento. Os métodos propostos foram baseados em estudos considerados o estado da arte, realizando, contudo, inovações, correções de falhas e otimização desses.

A validação dos métodos desenvolvidos é realizada de três maneiras: a primeira, analisa apenas o método de segmentação isoladamente, verificando sua eficácia por meio da comparação com 6 algoritmos de segmentação considerados o estado da arte, uma vez que uma segmentação de qualidade é importante para a processo completo de extração. A segunda forma de validação foi através da submissão do algoritmo de extração, juntamente com o algoritmo de *matching* desenvolvido por Araujo (2015), para a competição internacional FVC. A terceira forma foi através da comparação isolada do algoritmo de extração com outros três algoritmos de extração estado da arte, utilizando um único algoritmo de *matching*, além de bases de dados disponibilizadas pela FVC, e a métrica EER para obter os valores de erro de cada algoritmo. A descrição detalhada de cada etapa é mostrada a seguir.

Com relação à segmentação de imagens de impressão digital, o método proposto mostrou-se superior aos encontrados na literatura. O método de segmentação BioPass *Segmentation* obteve taxas de erro inferiores a todos os algoritmos comparados em 10 das 12

bases de dados testadas, alcançando na média geral de erros uma melhoria de 5,6% com relação ao melhor dos outros métodos. Além disso, verificou-se que a forma de segmentação utilizada (a região de interesse contempla toda a impressão digital na imagem) prejudica o processo de realce da imagem e, conseqüentemente, a extração de minúcias, devido ao fato de regiões irrecuperáveis da impressão digital, podem acarretar a geração de falsas minúcias, prejudicando o processo de casamento. Para corrigir este problema, foram utilizadas técnicas de processamento de imagens para retirar as regiões irrecuperáveis da imagem de impressão digital, conforme descrição na Seção 4.3.1 e demonstrado na Figura 4.7.

A segunda forma de avaliação do método de extração foi em relação à classificação na competição FVC, que avalia sistemas AFIS completos através de métricas como a EER. Ao analisar a colocação do método proposto nas versões anteriores do projeto FVC, obteve-se a primeira colocação, no FVC 2000; oitava colocação, no FVC 2002; sexta colocação, nos dois bancos testados da versão 2004 e a décima colocação na versão 2006.

Atualmente, o método proposto combinado ao método de casamento desenvolvido por Araujo (2015), está na décima quarta colocação na versão FVC-OnGoing, em vigor desde a última versão do BioPass, com um desempenho de 0,74% de EER. Neste momento não existem métodos de origem brasileira com resultados apresentados nesta competição além do método proposto.

A terceira e última forma de avaliação dos métodos desenvolvidos neste trabalho foi a comparação de algoritmos exclusivamente de extração, utilizando um método de casamento em comum para todos, a fim de obter resultados mais confiáveis e isolados apenas para a etapa de extração. Como resultados, observa-se que o método proposto obteve a segunda colocação, ficando atrás apenas do método de extração desenvolvido pela Neurotechnology, reconhecido como o melhor algoritmo da atualidade entre empresas e grupos de pesquisa. Além disso, o método proposto alcançou ganhos significativos em relação ao método desenvolvido por Turrone et al. (2012). Vale ressaltar que o método de Turrone et al. (2012) foi a base para este trabalho, e que, contudo, apresentava algumas falhas, que foram reduzidas, e o algoritmo desenvolvido neste trabalho obteve melhores resultados com relação à taxa de erros e ao tempo de processamento.

Para trabalhos futuros, existem diferentes linhas de pesquisa para melhorar o algoritmo e torná-lo ainda mais competitivo, diminuindo as taxas de erro e principalmente o tempo de

processamento. A proposta é pesquisar formas de utilizar valores de frequências variáveis para cada imagem, otimizando as convoluções. Além disso, existe a possibilidade da utilização de novos atributos, como singularidades e contagem de cristas, além do uso de redes neurais convolucionais, através do treinamento com imagens realçadas corretamente.

Em suma, diante do que foi exposto, pode-se considerar que este trabalho atingiu os objetivos esperados. Não obstante, embora a pesquisa científica utilizando a impressão digital já tenha avançado por longos anos, o método proposto é capaz de competir com os métodos que disputam o mercado, de acordo com os resultados apresentados, tanto em bases de dados controladas, quanto em uma competição internacional. Este trabalho apresenta um avanço para a biometria em âmbito nacional e para a pesquisa em âmbito internacional, tendo em vista que os principais algoritmos de reconhecimento de indivíduos por impressão digital pertencem à empresas privadas e localizadas fora do Brasil, e que não possuem interesse em publicar os detalhes do funcionamento dos algoritmos..

# Bibliografia

- Antonelli, A., Cappelli, R., Maio, D., e Maltoni, D. (2006). Fake finger detection by skin distortion analysis. *IEEE Transactions on Information Forensics and Security*, 1(3):360–373.
- Araujo, I. (2015). Uma Nova Abordagem de Casamento de Impressões Digitais. Master's thesis, Departamento de Informática, Universidade Federal da Paraíba.
- Barber, C. B., Dobkin, D. P., e Huhdanpaa, H. (1996). The quickhull algorithm for convex hulls. *ACM Transactions on Mathematical Software (TOMS)*, 22(4):469–483.
- Batista, L. V. (2005). Notas de aula da disciplina introdução ao processamento digital de imagens. *João Pessoa*.
- Bazen, A. M. e Gerez, S. H. (2001). Segmentation of fingerprint images. Em *Proc. Workshop on Circuits Systems and Signal Processing (ProRISC 2001)*, volume 276280. Citeseer.
- BioLab (2006). <https://biolab.csr.unibo.it/fvcongoing> . acesso: julho de 2016.
- Bolle, R. M., Connell, J. H., e Ratha, N. K. (2002). Biometric perils and patches. *Pattern Recognition*, 35(12):2727–2738.
- Cappelli, R., Ferrara, M., Franco, A., e Maltoni, D. (2007). Fingerprint verification competition 2006. *Biometric Technology Today*, 15(7):7–9.
- Cappelli, R., Ferrara, M., e Maltoni, D. (2010). Minutia cylinder-code: A new representation and matching technique for fingerprint recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(12):2128–2141.

- Carneiro, R. F. L., Bessa, J. A., De Moraes, J. L., Neto, E. C., e De Alexandria, A. R. (2014). Techniques of binarization, thinning and feature extraction applied to a fingerprint system. *International Journal of Computer Applications*, 103(10).
- Chikkerur, S., Cartwright, A. N., e Govindaraju, V. (2007). Fingerprint enhancement using stft analysis. *Pattern Recognition*, 40(1):198–211.
- Clarke, R. (1994). Human identification in information systems: Management challenges and public policy issues. *Information Technology & People*, 7(4):6–37.
- Costa, L. R., Obelheiro, R. R., e Fraga, J. S. (2006). Introdução á biometria. *Livro texto dos Minicursos do VI Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg2006)*. SBC: Porto Alegre, 1:103–151.
- Fleyeh, H. (2016). Segmentation and enhancement of low quality fingerprint images. Em *International Conference on Web Information Systems Engineering*, pgs. 371–384. Springer.
- Ghosh, A., Pal, N. R., e Pal, S. K. (1991). Image segmentation using a neural network. *Biological Cybernetics*, 66(2):151–158.
- Gonzalez, R. C., Eddins, S., e Woods, R. E. (2004). *Digital image processing using MATLAB*. Number 04; TA1637, G6.
- Harris, C. e Stephens, M. (1988). A combined corner and edge detector. Em *Alvey vision conference*, volume 15, pgs. 10–5244. Citeseer.
- Henry, E. R. (1905). *Classification and uses of finger prints*. HM Stationery Office.
- Hong, L., Wan, Y., e Jain, A. (1998). Fingerprint image enhancement: algorithm and performance evaluation. *IEEE transactions on pattern analysis and machine intelligence*, 20(8):777–789.
- Hsieh, C.-T., Lai, E., e Wang, Y.-C. (2003). An effective algorithm for fingerprint image enhancement based on wavelet transform. *Pattern Recognition*, 36(2):303–312.
- Jain, A. K., Ross, A., e Prabhakar, S. (2004). An introduction to biometric recognition. *IEEE Transactions on circuits and systems for video technology*, 14(1):4–20.

- Jain, A. K., Ross, A. A., e Nandakumar, K. (2011). Introduction. Em *Introduction to Biometrics*, pgs. 1–49. Springer.
- Jirachaweng, S. e Areekul, V. (2007). Fingerprint enhancement based on discrete cosine transform. Em *Advances in Biometrics*, pgs. 96–105. Springer.
- Kaggwa, F., Ngubiri, J., e Tushabe, F. (2014). Evaluation of multiple enrollment for fingerprint recognition. Em *Computer & Information Technology (GSCIT), 2014 Global Summit on*, pgs. 1–6. IEEE.
- Kirkpatrick, D. G. e Seidel, R. (1986). The ultimate planar convex hull algorithm? *SIAM journal on computing*, 15(1):287–299.
- Koh, J., Suk, M., e Bhandarkar, S. M. (1995). A multilayer self-organizing feature map for range image segmentation. *Neural Networks*, 8(1):67–86.
- Kulp, A. e Braskamp, H. (2012). Selecting identification technology. <http://nedap-securitymanagement.com/en/technology-nedapmenu-90/identificationtechnology-nedapmenu-61.html>. Online; Acessado em Agosto de 2017.
- Maio, D. e Maltoni, D. (1997). Direct gray-scale minutiae detection in fingerprints. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 19(1):27–40.
- Maltoni, D., Maio, D., Jain, A., e Prabhakar, S. (2009). *Handbook of fingerprint recognition*. Springer Science & Business Media.
- Marcialis, G. L., Roli, F., e Serrau, A. (2007). Graph-based and structural methods for fingerprint classification. Em *Applied Graph Theory in Computer Vision and Pattern Recognition*, pgs. 205–226. Springer.
- Msiza, I. S., Mathekg, M. E., Nelwamondo, F. V., e Marwala, T. (2011). Fingerprint segmentation: An investigation of various techniques and a parameter study of a variance-based method. *International Journal of Innovative Computing, Information, and Control (IJICIC)*, 7:5313–5326.
- Nascimento, M. V. P. d. et al. (2015). Um método de reconhecimento de indivíduos por geometria da mão. Master's thesis.

- Niwattanakul, S., Singthongchai, J., Naenudorn, E., e Wanapu, S. (2013). Using of jaccard coefficient for keywords similarity. Em *Proceedings of the International MultiConference of Engineers and Computer Scientists*, volume 1, pg. 6.
- o'Rourke, J. (1998). *Computational geometry in C*. Cambridge university press.
- Pappas, T. N. (1992). An adaptive clustering algorithm for image segmentation. *Signal Processing, IEEE Transactions on*, 40(4):901–914.
- Patrick, E. A. (1972). Fundamentals of pattern recognition.
- Ratha, N. K., Chen, S., e Jain, A. K. (1995). Adaptive flow orientation-based feature extraction in fingerprint images. *Pattern Recognition*, 28(11):1657–1672.
- Roberts, C. (2007). Biometric attack vectors and defences. *Computers & Security*, 26(1):14–25.
- Rojas, V., Aching, S., Jorge, L., et al. (2006). An improved method for segmentation of fingerprint images. Em *Electronics, Robotics and Automotive Mechanics Conference, 2006*, volume 2, pgs. 20–23. IEEE.
- Ross, A. A., Nandakumar, K., e Jain, A. (2006). *Handbook of multibiometrics*, volume 6. Springer Science & Business Media.
- Sankaran, A., Jain, A., Vashisth, T., Vatsa, M., e Singh, R. (2017). Adaptive latent fingerprint segmentation using feature selection and random decision forest classification. *Information Fusion*, 34:1–15.
- Schuckers, S. (2005). Clarkson university engineer outwits high-tech fingerprint fraud. *Clarkson University, Biomedical Signal Analysis Laboratory*.
- Shen, L., Kot, A., e Koo, W. (2001). Quality measures of fingerprint images. Em *Audio-and Video-based Biometric Person Authentication*, pgs. 266–271. Springer.
- Shen, W. e Eshera, M. (2004). Feature extraction in fingerprint images. Em *Automatic fingerprint recognition systems*, pgs. 145–181. Springer.

- Sherlock, B. G., Monroe, D., e Millard, K. (1994). Fingerprint enhancement by directional fourier filtering. Em *Vision, Image and Signal Processing, IEE Proceedings-*, volume 141, pgs. 87–94. IET.
- Shu, S.-G., Lin, H.-H., Kuo, S.-W., e Yu, S.-S. (2009). Excluding background initial segmentation for radiographic image segmentation.
- Thai, D. H. e Gottschlich, C. (2016). Global variational method for fingerprint segmentation by three-part decomposition. *IET Biometrics*, 5(2):120–130.
- Thai, D. H., Huckemann, S., e Gottschlich, C. (2016). Filter design and performance evaluation for fingerprint image segmentation. *PloS one*, 11(5):e0154160.
- Turrone, F., Cappelli, R., e Maltoni, D. (2012). Fingerprint enhancement using contextual iterative filtering. Em *Biometrics (ICB), 2012 5th IAPR International Conference on*, pgs. 152–157. IEEE.
- Važan, R. (2009). Sourceafis project.
- Wu, C., Tulyakov, S., e Govindaraju, V. (2007). Robust point-based feature fingerprint segmentation algorithm. Em *International Conference on Biometrics*, pgs. 1095–1103. Springer.