

Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Coordenação de Pós-Graduação em Ciência da Computação

Métodos para extração de atributos
em imagens de impressão digital

João Janduy Brasileiro Primo

Tese submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Campina Grande - Campus I como parte dos requisitos necessários para obtenção do grau de Doutor em Ciência da Computação.

Área de Concentração: Ciência da Computação
Linha de Pesquisa: Modelos Computacionais e Cognitivos

Herman Martins Gomes
(Orientador)

Leonardo Vidal Batista
(Orientador)

João Janduy Brasileiro Primo

Métodos para extração de atributos
em imagens de impressão digital

Tese submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Campina Grande - Campus I como parte dos requisitos necessários para obtenção do grau de Doutor em Ciência da Computação. Linha de pesquisa: Modelos Computacionais e Cognitivos

João Pessoa
2019

B823m Brasileiro Primo, João Janduy.
Métodos para extração de atributos em imagens de impressão digital / João Janduy Brasileiro Primo. – Campina Grande, 2019.
102 f. : il. color.

Tese (Doutorado em Ciência da Computação) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2019.

"Orientação: Prof. Dr. Herman Martins Gomes, Leonardo Vidal Batista".

Referências.

1. Biometria. 2. Impressão Digital. 3. Realce. 4. Segmentação. 5. Qualidade. 6. Extração de Características. I. Gomes, Herman Martins de. II. Batista, Leonardo Vidal. III. Título.

CDU 004:343.982.34(043)

João Janduy Brasileiro Primo

**Métodos para extração de atributos
em imagens de impressão digital**

Tese submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Campina Grande - Campus I como parte dos requisitos necessários para obtenção do grau de Doutor em Ciência da Computação. Linha de pesquisa: Modelos Computacionais e Cognitivos

Banca Examinadora

Prof. Dr. Herman Martins Gomes (Orientador) - UFCG

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

Prof. Dr. Eanes Torres Pereira - UFCG

Prof. Dr. Leandro Balby Marinho - UFCG

Prof. Dr. Tiago Pereira do Nascimento - UFPB

Prof. Dr. Tsang Ing Ren - UFPE

João Pessoa
2019

Aos meu pais, mães, esposa e amado filho

Agradecimentos

Agradeço imensamente a Deus, por ter me dado força para enfrentar todos as dificuldades, me guiar, iluminar e me dar tranquilidade para seguir em frente com os meus objetivos.

Aos meus pais, mães e avós, por todo apoio incondicional, incentivo, amizade e paciência demonstrados e total ajuda na superação dos obstáculos que ao longo desta caminhada foram surgindo. Aos meus irmão, tios, primos e demais familiares, por todo apoio dado.

À minha esposa Egliselma, por seu amor, companheirismo e cumplicidade.

Ao meu filho Arthur Gabriel, razão do meu viver.

Aos meus orientadores: Dr. Herman Martins Gomes, por todo apoio e ensinamento prestado durante todo o tempo e Dr. Leonardo Vidal Batista, por ser um exemplo de professor e pela amizade construída.

A todos meus professores, em especial Antônio Carlos, Hamilton Soares e José Antônio, pelos ensinamentos que levarei por toda vida.

A Vsoft, por acreditar em mim e investir no meu trabalho e aos meus amigos do grupo de P&D, sem eles nada disso seria possível.

Por fim, agradeço a todos que um dia me ajudaram e fazem de mim uma pessoa melhor.

Resumo

Entre as várias características dos indivíduos que podem ser usadas em um sistema biométrico, as impressões digitais têm sido amplamente utilizadas, pois permitem alta precisão e exigem equipamentos de baixo custo. No entanto, o reconhecimento de impressões digitais ainda é um problema com lacunas de melhoria nos erros de falsa aceitação e falsa rejeição presentes em algoritmos de última geração. A confiabilidade desses algoritmos depende da qualidade da imagem da impressão digital e da informação extraída para realizar o reconhecimento. Neste contexto, a presente tese propõe novos métodos para a extração de atributos usando técnicas de segmentação, aprimoramento e definição de qualidade. Nosso objetivo é reduzir as taxas de erro e alcançar resultados competitivos no estado-da-arte. Esta tese apresenta um novo algoritmo para avaliação da qualidade global a partir de uma imagem de impressão digital, o que contribui para a redução de falsos positivos e diminui as taxas de erro. Os resultados mostraram que 10% das imagens de pior qualidade são responsáveis por mais de 60% dos erros. Além disso, um novo algoritmo para delimitar a região de interesse da impressão digital foi desenvolvido, superando trabalhos concorrentes com um aumento médio de 5,6% na precisão. Finalmente, propomos melhorias no processo de aprimoramento de impressões digitais inspiradas nas seguintes abordagens encontradas na literatura: ajuste de contraste, filtros Gabor e filtragem de domínio de frequência. Os métodos foram avaliados em relação às taxas de erro obtidas por um algoritmo para comparação de impressões digitais usando as bases de dados *Fingerprint Verification Competition* - (FVC 2000, 2002, 2004 e 2006) e *FVC OnGoing*. Os métodos apresentaram resultados competitivos em comparação outros trabalhos nas mesmas bases de dados.

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

Abstract

Among the various characteristics of individuals that can be used in a biometric system, fingerprints have been widely used as they enable high accuracy and require low-cost equipment. However, fingerprint recognition is still a problem with gaps for improvement on the false acceptance and false rejection errors present in state-of-the-art algorithms. The reliability of these algorithms depends on the quality of the fingerprint image and the information extracted to perform recognition. In this context, the present thesis proposes new methods for attribute extraction using innovative segmentation, enhancement, and quality definition techniques. We aim to reduce error rates and achieve competitive state-of-the-art results. This thesis presents a new algorithm for evaluation of the global quality from a fingerprint image, which contributes to the false positive reduction and decreases the error rates. The results showed that 10% of the worst quality images are responsible for more than 60% of the errors. Also, a new algorithm for delimiting the region of interest of the fingerprint was developed, outperforming competing works with an average increase of 5.6% on accuracy. Finally, we propose improvements in the fingerprint enhancement process inspired by the following approaches found in the literature: contrast adjustment, Gabor filters, and frequency domain filtering. The methods were evaluated in respect to the error rates obtained by an algorithm for fingerprint matching using the Fingerprint Verification Competition - (FVC 2000, 2002, 2004 and 2006) and FVC OnGoing databases. The methods presented competitive results in comparison to other approaches on the same databases.

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

Conteúdo

1	Introdução	1
1.1	Problema	3
1.2	Motivação	4
1.3	Objetivos	5
1.4	Estrutura da Tese	6
2	Conceitos Gerais	7
2.1	Biometria	7
2.2	Sistemas Biométricos	9
2.3	Impressão Digital	12
2.4	Sistemas Biométricos para Impressão Digital	16
2.4.1	Extração de Características	16
2.4.2	Padrão ISO de <i>Template</i>	20
2.4.3	Casamento entre Impressões Digitais	21
2.4.4	Métricas de Erro	23
2.5	Competição de Verificação de Impressões Digitais	25
2.6	Imagens e Processamento Digital de Imagens	26
2.6.1	Binarização	27
2.6.2	Filtro da Mediana	27
2.6.3	Segmentação	28
2.7	Coefficiente de Similaridade de Jaccard	29
2.8	Métrica de Comparação de Thai et al.	30
2.9	Filtros de Gabor	30
2.10	Envoltória Convexa	33

2.11	Medida de Assimetria	33
3	Trabalhos Relacionados	35
3.1	Trabalhos Relacionados sobre o Tema ROI	35
3.2	Trabalhos Relacionados sobre Avaliação de Qualidade	39
3.3	Trabalhos Relacionados sobre o Tema Realce	40
4	Metodologia	44
4.1	Materiais	44
4.1.1	Ambiente de Desenvolvimento	44
4.1.2	Bases de Dados	44
4.1.3	Hardware	45
4.2	Método Proposto	46
4.3	Processo de realce da imagem de impressão digital	47
4.3.1	Pré-processamento	48
4.3.2	Convolução Gabor Adaptativo	50
4.3.3	Segmentação da Região de Interesse	55
4.3.4	Avaliação da Qualidade Global	63
4.3.5	Realce da Impressão Digital (<i>Enhancement</i>)	67
4.4	Afinamento, Localização e Filtragem de Minúcias	69
4.5	Metodologia de Avaliação	71
5	Resultados e Discussões	74
5.1	Resultados de Segmentação	74
5.2	Resultados da Avaliação da Qualidade da Impressão Digital	78
5.2.1	Análise da Correlação	78
5.2.2	Impacto da Qualidade na Taxa de Erro	80
5.3	Resultados na Melhoria do Realce	84
5.3.1	Retirada de Regiões Irrecuperáveis na Impressão Digital	84
5.3.2	Comparação com outros Trabalhos	86
5.3.3	Avaliação do AFIS BioPass	88

6	Considerações Finais	91
6.1	Conclusão	91
6.2	Contribuição para a academia	93
6.3	Trabalhos futuros	93
	Referências bibliográficas	102

Siglas e Abreviaturas

AFIS : *Automated Fingerprint Identification System*

API : *Application Programming Interface*

BMP : *Windows Bitmap*

BPFQ: *BioPass Fingerprint Quality*

DDR3 : *Double Data Rate 3*

DPI : *Dots Per Inch*

EER : *Equal Error Rate*

FAR : *False Acceptance Rate*

FQA : *Fingerprint Quality Assessment*

FQS : *Fingerprint Quality Score*

FRR : *False Rejection Rate*

FVC : *Fingerprint Verification Competition*

GAR : *Genuine Accept Rate*

GB : *Giga Byte*

IDE : *Integrated Development Environment*

NFIQ : *NIST Fingerprint Image Quality*

NIST : *National Institute of Standards and Technology*

RAM : *Random Access Memory*

ROC : *Receiver Operator Characteristic Curve*

ROI : *Region of Interest*

SDK : *Standard Development Kit*

Lista de Figuras

2.1	Um modelo simples de sistema Biométrico. Adaptado de Costa et al. (2006)	11
2.2	Gráfico de segurança versus conveniência para alguns traços biométricos. Fonte: Kulp, A. e Braskamp, H. (2012)	12
2.3	Comparação dos sistemas de traços biométricos em relação ao custo e precisão.	12
2.4	Cristas e vales de uma impressão digital. Fonte: Maltoni et al. (2009)	13
2.5	Regiões de singularidade (Caixas brancas) e núcleo (Círculos brancos) em impressões digitais. Fonte: Maltoni et al. (2009)	14
2.6	Principais tipos de minúcias. Fonte: Maltoni et al. (2009)	14
2.7	Representação dos principais tipos de minúcia: a) bifurcação e b) terminação. A minúcia possui coordenadas $[X_0, Y_0]$ e ângulo (θ) que a tangente da minúcia forma com o eixo horizontal. Fonte: adaptado de ISO/IEC 19794-2:2005 (2005)	15
2.8	Detalhes extraídos no nível 3 de uma impressão digital: a) parte de uma impressão digital, capturada a 1000 DPI, onde os poros ficam bem evidentes; b) novas cristas; c) vincos e cicatrizes. Fonte: Bennet and Arumuga (2011).	15
2.9	Impressões digitais de qualidades diferentes. Fonte: Bennet and Arumuga (2011).	18
2.10	Imagem de Impressão Digital com regiões de qualidades diferentes: a) região bem definida; b) região recuperável; c) região irrecuperável; d) região que não pertence à impressão digital; e) região com traços de digitais remanescentes de outras capturas. Fonte: Zhu et al. (2006)	19
2.11	Amostras deslocadas, rotacionadas e com ruído. Fonte: próprio autor. . . .	22

2.12	As curvas típicas das taxas de erro FAR e FRR 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 et al. (2006).	24
2.13	Notação matricial de imagem digital monocromática. Fonte: Batista (2005).	26
2.14	Exemplo de Binarização: (a) imagem original, (b) resultado da aplicação da binarização. Fonte: próprio autor.	27
2.15	Exemplo de aplicação da mediana: (a) Imagem original, (b) Resultado após a aplicação do filtro da mediana de dimensões 5x5	28
2.16	Segmentação de impressão digital. Fonte: próprio autor.	29
2.17	Sobreposição de duas regiões de interesse de uma mesma impressão digital. Fonte: próprio autor	30
2.18	Representação gráfica (visão lateral e superior) do filtro de Gabor. Fonte: Turrone et al. (2012).	31
2.19	Um conjunto de filtros de Gabor com seis orientações θ (colunas) e 3 frequências f (linhas). Fonte: Turrone et al. (2012)	32
2.20	Convolução com filtros de Gabor de diferentes orientações. Fonte: próprio autor.	32
2.21	Exemplos da função envoltória convexa aplicada em: a) pontos em um plano bidimensional e b) pontos em um espaço tridimensional. Fonte: Weisstein (2016)	33
2.22	Representação gráfica de uma distribuição. (A) Distribuição com cauda para esquerda (assimetria negativa). (B) Distribuição com cauda para direita (assimetria positiva). Fonte: próprio autor	34
3.1	Etapas do processo de realce de imagens de impressões digitais proposto por Turrone et al. Fonte: (Turrone et al., 2012)	43
3.2	Evolução de uma imagem ruidosa de impressão digital durante o processo iterativo de realce. O realce iterativo ocorre da esquerda para a direita e a cada iteração mais regiões da imagem são recuperadas. Fonte: (Turrone et al., 2012)	43

4.1	Etapas do processo proposto de extração de minúcias em uma imagem de impressão digital. Fonte: próprio autor.	47
4.2	Etapas do processo proposto de realce da imagem de impressão digital com extração da ROI e escore de qualidade. Fonte: próprio autor.	48
4.3	Etapas do processo proposto para o pré-processamento das imagens de impressão digital. Fonte: próprio autor.	49
4.4	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 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 aplicação da equalização de histograma. Fonte: próprio autor.	50
4.5	Etapas do processo de convolução com máscaras de Gabor adaptativa. Fonte: próprio autor.	51
4.6	Sinais de saída do filtro de Gabor utilizando frequências diferentes e σ fixo. Fonte: próprio autor.	52
4.7	Sinal de saída do filtro de Gabor utilizando frequências diferentes e σ definido dinamicamente de forma adaptativa. Fonte: próprio autor.	52
4.8	Imagens Combinadas utilizando σ fixo (a,c) e σ definido dinamicamente de forma adaptativa (b,d). Fonte: próprio autor.	54
4.9	Fluxograma com todos os passos realizados no método de segmentação proposto. Fonte: próprio autor.	57
	58figure.4.10	
4.11	Imagem de impressão digital (a) segmentada de duas formas utilizando diferentes conceitos: (b) imagem separada em região pertencente à impressão digital e (c) região recuperável impressão digital. Fonte: próprio autor.	59

4.12	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 et al. (2016). A região branca é a região de interseção. Fonte: próprio autor.	61
4.13	Processo de avaliação da qualidade de uma impressão digital. Fonte: próprio autor.	64
4.14	Ilustração da análise de P_{abs} . A coluna da esquerda são exemplos de impressão digital e a coluna da direita (imagens (b), (d), (f) e (h)) é o histograma de P_{abs} calculado a partir da respectiva imagem de impressão digital. As imagens (a) e (c) são impressões digitais de melhor qualidade do que (e) e (g). Fonte: próprio autor.	65
4.15	Realce de impressões digitais por meio das diferentes abordagens de segmentação. Fonte: próprio autor.	68
4.16	Binarização local. Fonte: próprio autor.	70
4.17	Aplicação do filtro da mediana local. Fonte: próprio autor.	70
4.18	Afinamento das cristas. Fonte: próprio autor.	70
4.19	Remoção de falsas minúcias. Fonte: próprio autor.	71
5.1	Diferentes taxas de erro entre as imagens segmentadas pelo método proposto 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%). Fonte: próprio autor.	76
5.2	Relação entre o escore de casamentos genuínos e o menor escore de qualidade dos seus respectivos <i>templates</i> no banco FVC2000DB3. Fonte: próprio autor.	78
5.3	Relação entre o escore de casamentos genuínos e o menor escore de qualidade dos seus respectivos <i>templates</i> no banco FVC2002DB1. Fonte: próprio autor.	80

5.4	Taxa de erro igual obtida pelo AFIS BioPass quando removidos 10% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.	81
5.5	Taxa de erro igual obtida pelo AFIS da VeriFinger quando removidos 10% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.	82
5.6	Taxa de erro igual obtida pelo AFIS BioPass quando removidos 20% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.	83
5.7	Taxa de erro igual obtida pelo AFIS da VeriFinger quando removidos 20% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.	84
5.8	Realce de imagens de impressões digitais com regiões irrecuperáveis. (a) Imagem original presente na base de dados do FVC2004; (b) Realce utilizando o método iterativo contextual Turrone et al. (2012); (c) Realce utilizando o método desenvolvido. Fonte: próprio autor.	85
5.9	Realce de impressões digitais com vários algoritmos. (a) Imagem original presente no banco de dados do FVC2006DB2, (b) Aprimorado usando filtros de Gabor (Hong et al., 1998), (c) Aprimorado usando o método iterativo contextual (Turrone et al., 2012), (d) Aprimorado usando o método proposto. Círculos verdes indicam as regiões que foram corretamente melhoradas usando o método proposto, enquanto que os círculos vermelhos são as mesmas regiões, mas aumentadas incorretamente por Turrone et al. (2012). Fonte: próprio autor.	87

Lista de Tabelas

2.1	Comparação dos traços biométricos mais utilizados. As entradas na figura são baseadas nas percepções dos autores. Alta, Média e Baixa são denotadas por A, M e B, respectivamente. Fonte: Sabhanayagam et al. (2018)	9
4.1	Características das Bases de Dados	45
4.2	Parâmetros utilizados no método proposto.	62
4.3	Visão geral sobre os valores dos parâmetros mais relevantes definidos no conjunto de treinamento.	63
5.1	Comparação dos métodos utilizando o método de comparação proposto por Thai et al. Os valores representam a taxa de erro da imagem segmentada em relação ao gabarito.	75
5.2	Taxas de erros obtidas pela diferença entre as imagens segmentadas pelo método de segmentação proposto e as imagens segmentadas manualmente criadas por Thai et al., utilizando as duas técnicas de comparação citadas (Jaccard e Thai et al.).	77
5.3	Coefficiente de correlação de <i>Pearson</i> entre o escore de casamento e a qualidade dos <i>templates</i> para os algoritmos NFIQ, VeriFinger e o desenvolvido nessa tese (BPFQ).	79
5.4	Avaliação dos algoritmos de realce a partir da EER obtida pelo algoritmo de casamento <i>BioPass Match</i>	86
5.5	Avaliação dos algoritmos de realce a partir da EER obtida pelo algoritmo de casamento MCC.	88
5.6	Desempenho do método proposto, de cor verde, em relação aos demais candidatos em todas as versões do FVC.	89

Capítulo 1

Introdução

Os seres humanos utilizam características físicas ou comportamentais, tais como face, voz e modo de caminhar, para reconhecer uns aos outros. Com o passar do tempo surgiu a necessidade de utilizar esse reconhecimento de modo mais preciso e automatizado. Isto se deve, principalmente, 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 (Marcialis et al., 2007), identificando-os a partir de características que foram previamente armazenadas em bancos de dados.

A necessidade do uso de sistemas que pudessem identificar um indivíduo surgiu durante o século dezenove. Um dos principais 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. Tentando evitar essas fraudes, 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, observou 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 resquícios de impressões digitais em cenas de 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 eram suficientes para a quantidade de requisições que surgiam. O método manual de indexação da impressão digital (com base no sistema de classificação de Henry) 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 digitais requeria cada vez mais recursos para suprir a demanda. A monotonia do trabalho e o aumento na carga horária decorrentes 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, aliados aos avanços tecnológicos na computação, levaram ao desenvolvimento de Sistemas de Identificação Automática de Impressões Digitais (AFIS) ao longo das últimas quatro décadas (Maltoni et al., 2009). Um AFIS deve satisfazer os requisitos de reconhecimento de precisão, velocidade e recursos, além de ser inofensivo para os usuários, ser aceito pela população a que se destina e ser suficientemente robusto para possíveis ataques ao sistema e métodos fraudulentos (Jain et al., 2004).

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 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 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 para estabelecer a identidade do 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 manipulados para enganar o sistema.

A autenticação biométrica por sua vez, não se baseia no conhecimento ou posse, mas em características (dedos, olhos, face), sendo considerado a princípio um método mais seguro, por exigir a apresentação de uma característica e, portanto, sua presença ao menos no momento da autenticação.

1.1 Problema

O reconhecimento por impressão digital é uma das abordagens biométricas mais utilizadas, visto que sua alta precisão e seu baixo custo tornam os sistemas mais acessíveis e, na maioria dos casos, com resultados melhores. 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 métodos de comparação de impressões digitais.

A confiabilidade desses métodos depende da qualidade da impressão digital observada. Se a qualidade é elevada, então, um conjunto confiável de características pode ser extraído, caso contrário, quando a impressão possui muito ruído, por exemplo, o método pode detectar um grande número de falsas características e perder características verdadeiras (Turroni et al., 2012), dificultando o processo de reconhecimento, o que pode resultar em taxas elevadas de falsa aceitação e falsa rejeição. Uma ampla variedade de fatores influencia a qualidade de uma imagem de impressão digital, como condições da pele (secura, umidade, sujeira, cortes e contusões), condições do sensor (sujeira, ruído, tamanho) e outras condições de aquisição, como cooperação do usuário, preservação da cena do crime em cenários forenses, etc.

Em muitos casos as imagens capturadas possuem regiões que não pertencem à impressão digital. Essas regiões muitas vezes acarretam a geração de erros indesejáveis, como a detecção de falsas características, prejudicando o processo de comparação entre imagens de impressões digitais. Para diminuir esses problemas foram desenvolvidos métodos que detectam as regiões de *background* e *foreground*, onde *foreground* é a região de interesse (*Region*

of Interest - ROI), ou seja, região pertencente a uma impressão digital. Porém, esses métodos podem gerar falhas como a manutenção de regiões que não são relevantes ou a retirada de regiões da imagem que pertencem à impressão digital.

Outro problema é a necessidade de processar a imagem da região da impressão digital adquirida. Por diversos motivos (sensores de má qualidade ou com sujeira, dedo sujo ou com cicatrizes), a impressão digital pode apresentar regiões 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 das características e o reconhecimento da impressão digital, buscando destacar as linhas das impressões digitais 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 tem ambas as propriedades de frequência e orientação seletiva e têm resolução conjunta ideal em ambos os domínios espacial e de frequência. O método de realce apresentado por Turrioni et al. (2012), mostra-se bastante eficiente e consiste em uma filtragem contextual e com aplicação iterativa de filtros de Gabor. 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 métodos de realce que utilizam filtros de Gabor na literatura apresentam erros em 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, esta pesquisa apresenta métodos para extração de atributos em imagens de impressão digital, para a criação e comparação de *templates*.

1.2 Motivação

A literatura apresenta trabalhos que são deficientes quando se trata de impressões digitais em casos especiais, como capturas de baixa qualidade ou de impressões digitais parciais. Nesses

casos, a delimitação da ROI não ocorre de forma eficaz, retirando regiões pertencentes à imagem da impressão digital ou incluindo regiões que não são. Além disso, o processo de realce pode criar falsas características quando é aplicado em regiões que não pertencem à impressão digital ou em regiões que pertencem, mas não podem ser recuperadas.

Além disso, 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 método. 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 na *Fingerprint Verification Competition* (FVC) (BioLab, 2006), que é uma competição de referência mundial em que se verifica o desempenho de métodos de identificação por meio de impressão digital, não existem métodos produzidos no Brasil. Isso implica perda de espaço e de oportunidades, quando se trata de mercado comercial público e privado, onde são priorizados produtos pesquisados e desenvolvidos (Lei de Licitações, 8.666 de 1993; Instrução Normativa 04, 2010). Dessa forma, um método tão eficaz, quanto os produzidos em outros países, terá prioridade em licitações, como por exemplo: sistemas biométricos utilizados em votações eleitorais, fornecidos pelos Tribunais Eleitorais, que são sistemas que atuam em grande escala de uso.

O método de casamento de impressões digitais desenvolvido por Araújo (2015) obteve 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 Araújo (2015) para criar um AFIS completo.

1.3 Objetivos

O objetivo geral desta tese foi pesquisar e desenvolver métodos para as diversas etapas de extração de características de impressões digitais, com foco na melhoria das etapas de segmentação e realce da impressão digital, além da avaliação da qualidade da impressão digital. Os objetivos específicos foram:

- Pesquisar e propor método para extração da região de interesse de uma imagem de impressão digital, facilitando a atuação do método de realce e otimizando o processamento;
- Pesquisar e propor algoritmo para mensurar a qualidade da impressão digital capturada;
- Aperfeiçoamento do método de realce em imagens de impressão digital;
- Realizar extração de características necessárias para a identificação de um indivíduo por meio de sua impressão digital;
- Realizar análise comparativa do tempo de processamento do método desenvolvido com métodos da literatura em diferentes bases de dados;
- Avaliar taxas de acertos, erros, e desempenho sobre bases de dados reconhecidas internacionalmente;
- Obter resultados competitivos em âmbito internacional na identificação de indivíduos por impressão digital.

1.4 Estrutura da Tese

No próximo capítulo é apresentada a fundamentação teórica necessária para o entendimento deste trabalho. Em seguida, no Capítulo 3, são apresentadas as pesquisas relacionadas presentes na literatura, tanto na área de segmentação de impressões digitais quanto na área de realce e melhoria da qualidade. No Capítulo 4, o método proposto é apresentado juntamente com os métodos de avaliação utilizados e os materiais de pesquisa. No Capítulo 5 são apresentados os resultados e a discussão. E no Capítulo 6 são feitas as considerações finais e apresentadas as conclusões da pesquisa.

Capítulo 2

Conceitos Gerais

Neste capítulo, são apresentados os principais conceitos teóricos empregados nesta pesquisa, 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 falhas nas respostas podem representar riscos tanto para empresas como para 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. Consequentemente, 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 características físicas ou comportamentais para

reconhecer e identificar indivíduos. Tais características são os identificadores biométricos e podem abranger impressões digitais, face, íris, voz, forma de escrever etc. Conforme Clarke (1994), qualquer dessas características pode ser usada como característica biométrica desde que ela satisfaça alguns requisitos básicos:

- *Universalidade*: toda a população (a ser autenticada) deve possuir a característica;
- *Distinção*: indica o quanto um traço biométrico distingue um indivíduo do outro;
- *Permanência*: a característica deve ser imutável num longo intervalo de tempo;
- *Coleta*: a característica 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 da característica deve ser tolerada pelo indivíduo em questão;
- *Robustez a fraude*: indica a dificuldade de enganar o sistema.

É importante salientar que, na prática, nenhuma característica biométrica atende com perfeição a todos os requisitos de uma característica biométrica ideal (Clarke, 1994).

Pode-se observar na Figura 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 por meio de sistemas digitais apropriados (escâneres).

Tabela 2.1: Comparação dos traços biométricos mais utilizados. As entradas na figura são baseadas nas percepções dos autores. Alta, Média e Baixa são denotadas por A, M e B, respectivamente. Fonte: Sabhanayagam et al. (2018)

Traço biométrico	Universalidade	Distinguiabilidade	Coletabilidade	Permanência	Desempenho	Aceitabilidade	Circunvenção
Impressão digital	M	A	M	A	A	M	M
Face	A	M	A	M	B	A	A
Geometria da mão	A	M	A	B	M	M	M
Íris	A	A	A	A	A	M	B
Retina	A	A	M	A	A	B	B
Assinatura	B	B	A	B	M	A	A
Voz	M	B	M	B	B	A	A
Impressão palmar	M	A	M	A	A	M	M
DNA	A	A	B	A	A	B	B
Forma de andar	A	M	A	M	B	M	M
Odor	A	A	B	A	B	M	B
Orelha	M	M	M	A	M	A	M
Pressionamento de tecla	B	B	M	B	B	M	M
Veia da mão	M	M	M	M	M	M	B
Mapa de calor	A	A	A	B	M	A	B

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 benefícios (Maltoni et al., 2009).

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 a característica biométrica capturada com o modelo de referência biométrico anteriormente capturado, registrado no sistema. É feita uma comparação um-para-um (1:1) para confirmar a identidade do indivíduo. O sistema pode aceitar ou rejeita o pedido de verificação de identidade.

Sistemas de identificação por sua vez reconhecem um indivíduo por meio de uma busca em todos os registros de um banco de dados, retornando uma lista de registros com atributos suficientemente similares ao traço biométrico apresentado. 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 (Mittal et al., 2015).

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 sistema biomérico como segue:

- *Aquisição e exemplar*: O processo de aquisição ou apresentação é o processo de obtenção dos dados da característica biométrica oferecida. 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, denominado 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. 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 temos um usuário não autenticado.

A Figura 2.1 resume o processo de um sistema biométrico.

Figura 2.1: Um modelo simples de sistema Biométrico. 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 mostra um gráfico comparativo entre alguns traços biométricos, considerando segurança *versus* conveniência.

Figura 2.2: Gráfico de segurança versus conveniência para alguns traços biométricos. Fonte: Kulp, A. e Braskamp, H. (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 de traços biométricos em relação ao custo e precisão.



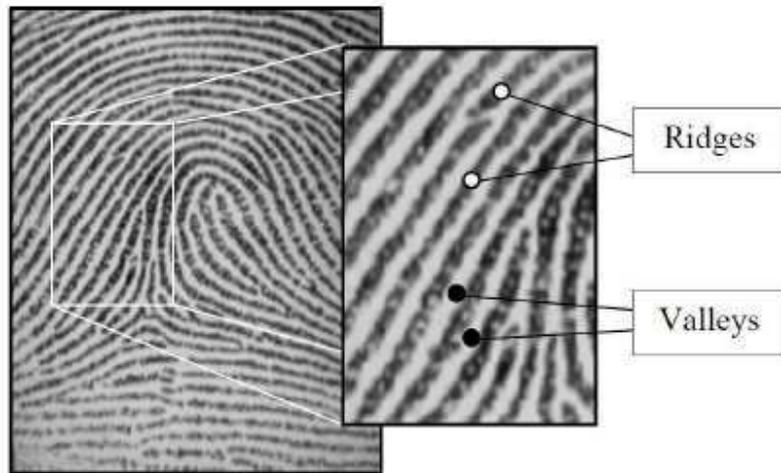
Pode-se verificar que sistemas biométricos baseados em impressões digitais ainda possuem o melhor custo-benefício, apesar de não serem tão convenientes quanto outros sistemas como o de face, onde não há a necessidade de contato com sensores.

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 (*ridges* e *valleys*). 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 μm , para os mais finos, até 300, μm para os mais largos. 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 (Ashbaugh, 1999).

Figura 2.4: Cristas e vales de uma impressão digital. Fonte: Maltoni et al. (2009)

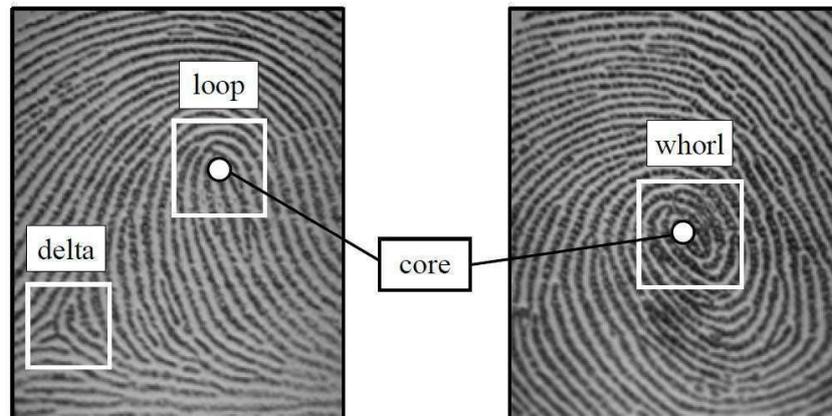


Os detalhes são geralmente descritos em uma ordem hierárquica de três níveis diferentes, nomeados: Nível 1 (Padrão Global de disposição das cristas), Nível 2 (Minúcias), e Nível 3 (Poros, formato das arestas locais das cristas) (Jain et al., 2006). No nível global (Nível 1), as cristas vizinhas geralmente possuem a mesma direção, 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 topologias: laço, delta e verticilo (*loop, delta and whorl*) (Figura 2.5). Existem situações em que um verticilo não é apresentado pois pode ser descrita como dois laços.

Métodos de comparação de impressões digitais (métodos de *matching*) podem pré-alinhar as imagens baseados em um ponto central, chamado de núcleo (*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 laço ou verticilo, nesse caso, o núcleo 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 núcleo confiável em todas as amostras.

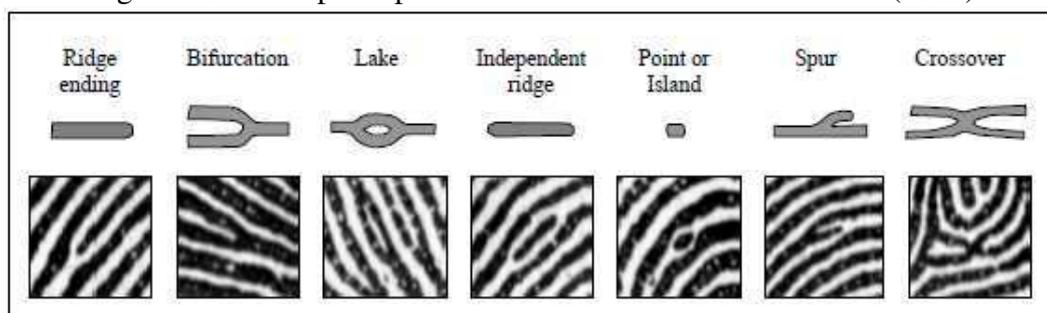
No nível 2, em um escopo menor, outras características podem ser encontradas como as minúcias. No contexto das impressões digitais refere-se às diferentes maneiras que uma

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



crista pode ser descontinuada. Uma crista pode acabar subitamente gerando uma terminação (*ridge ending*), ou pode sofrer uma bifurcação e se dividir em duas cristas (*ridge bifurcation*). As minúcias são as características mais utilizadas nos métodos 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), mas apenas alguns tipos são utilizados (Zhao and Tang, 2007).

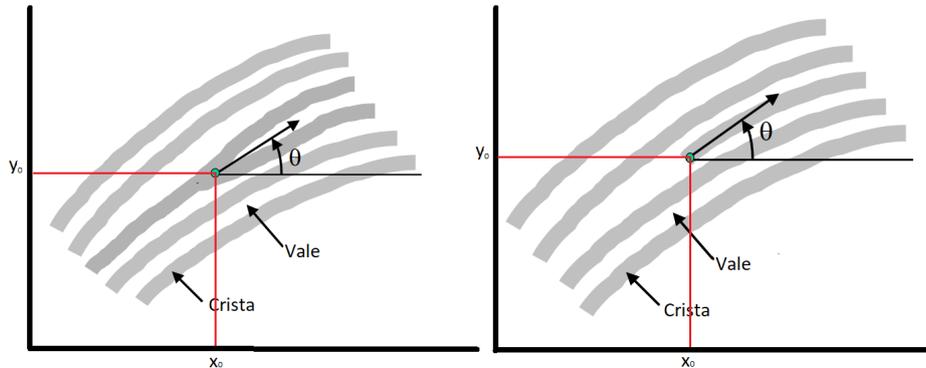
Figura 2.6: Principais tipos de minúcias. Fonte: Maltoni et al. (2009)



O modelo utilizado pelo FBI é baseado nas coordenadas das minúcias e utiliza apenas terminações e bifurcações. Cada minúcia é classificada pelas suas coordenadas cartesianas, e pelo ângulo em relação à reta tangente a crista no ponto da minúcia. (Figura 2.7).

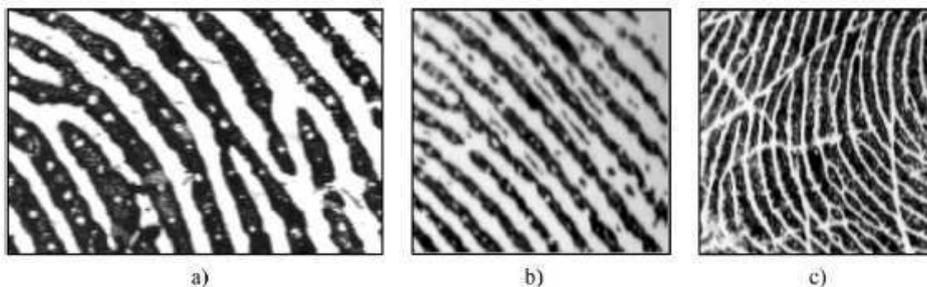
No nível 3, detalhes mais finos podem ser extraídos de uma impressão digital. Nesse nível

Figura 2.7: Representação dos principais tipos de minúcia: a) bifurcação e b) terminação. A minúcia possui coordenadas $[X_0, Y_0]$ e ângulo (θ) que a tangente da minúcia forma com o eixo horizontal. Fonte: adaptado de ISO/IEC 19794-2:2005 (2005)



estão incluídos todos os atributos dimensionais das cristas, como largura, formato, contorno das bordas, poros, vincos e cicatrizes. Cada crista é dotada de poros em toda sua extensão. O tamanho dos poros pode variar entre 60 e 250 μm . Estudos revelam que o número de poros por centímetro de crista situa-se 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 métodos 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 alta qualidade. Na Figura 2.8 é possível observar os detalhes de uma impressão digital no nível 3.

Figura 2.8: Detalhes extraídos no nível 3 de uma impressão digital: a) parte de uma impressão digital, capturada a 1000 DPI, onde os poros ficam bem evidentes; b) novas cristas; c) vincos e cicatrizes. Fonte: Bennet and Arumuga (2011).



2.4 Sistemas Biométricos para Impressão Digital

Os Sistemas de Identificação Automática de Impressões Digitais (*Automatic Fingerprint Identification Systems - AFIS*) são sistemas biométricos voltados para extração de atributos e identificação de indivíduos por meio de impressões digitais.

Historicamente, a captura das impressões digitais era realizada no “método de tinta”, em que os dedos eram impregnados em tinta preta e pressionados ou rolados sobre um cartão branco; depois o cartão era escaneado por *scanners* de propósito geral. Esse tipo de processamento era conhecido como captura *offline* de impressões digitais.

A coleta de impressões digitais deixadas em cenas de crime é um exemplo de uso da captura *offline*. Hoje em dia, a maioria dos AFIS, tanto de propósito civil quanto criminal, obtém imagens digitais a partir da aplicação direta de sensores eletrônicos sobre superfícies que contenham impressões digitais, ou da aplicação de dedos sobre os sensores. Nenhuma tinta é necessária para esse método e tudo o que se deve fazer é colocar o dedo no *scanner*.

Uma vez capturada, a imagem de impressão digital passa por duas etapas básicas: a primeira é o processo de extração de características, em que são obtidos todos os atributos necessários para a identificação ou verificação dos indivíduos. Após a aquisição, os atributos podem ser comparados com outro conjunto de atributos ou podem ser salvos em um banco de dados para futuras comparações. A segunda etapa é a comparação, onde dois conjuntos de atributos são comparados e é determinado o grau de similaridade entre eles, chamado de *escore*.

2.4.1 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 $60 \mu m$. Conforme discutido anteriormente, embora tais características sejam altamente distintivas, a sua extração somente é viável em imagens de alta resolução (cerca de 1.000 dpi) obtidas de impressões digitais de alta 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 métodos. 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 método de casamento. Além disso, ajuda a criar bancos de dados que podem ser usados por muitas instituições de pesquisa, da iniciativa privada ou governamentais. O padrão ISO utiliza obrigatoriamente informações de minúcias e pode conter informações de singularidades e contagem de cristas entre minúcias.

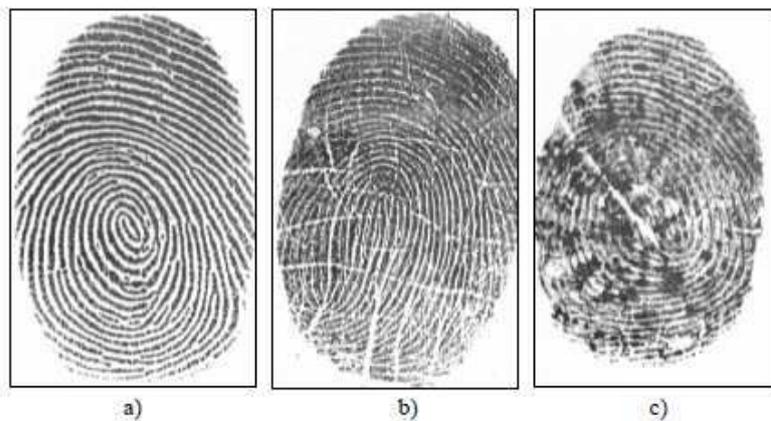
Com o objetivo de padronizar a geração de *templates* e comparar todos os métodos de forma justa, para o presente trabalho foram utilizados métodos de extração de características com abordagem local, apenas.

O desempenho dos métodos 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 detectados 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 com impressão digital comprometida (idosos, trabalhadores manuais), uma porcentagem de imagens de

impressões digitais (aproximadamente 10%) é de baixa qualidade como as mostradas na Figura 2.9(b), (c). Em muitos casos, uma única imagem de impressão digital contém regiões de alta, 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. Fonte: Bennet and Arumuga (2011).



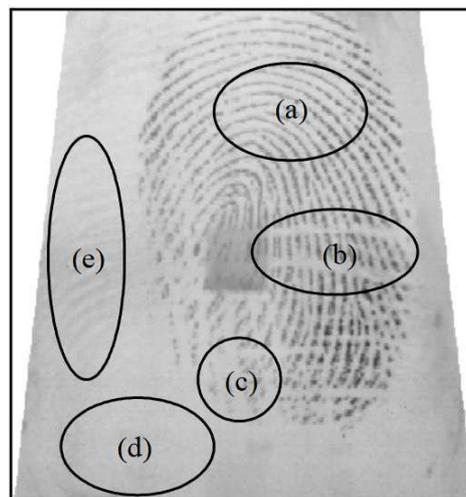
Esses três tipos de degradação tornam a extração de cristas extremamente difícil em regiões muito corrompidas. Isso leva aos seguintes problemas na extração de minúcias: (i) um elevado número de falsas minúcias extraído, (ii) um potencial número de minúcias genuínas é perdido, e (iii) erros na localização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

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 método 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 5 diferentes categorias (Zhu et al., 2006) (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 fornecem informações suficientes sobre a sua verdadeira estrutura.
- *Regiões irrecuperáveis*: cristas estão corrompidos 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.
- *Regiões sem cristas*: regiões que não fazem parte da impressão digital.
- *Regiões com digitais remanescentes*: regiões com partes de impressões digitais provenientes de outras capturas.

Figura 2.10: Imagem de Impressão Digital com regiões de qualidades diferentes: a) região bem definida; b) região recuperável; c) região irrecuperável; d) região que não pertence à impressão digital; e) região com traços de digitais remanescentes de outras capturas. Fonte: Zhu et al. (2006)



O principal objetivo do método 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).

2.4.2 Padrão ISO de *Template*

O padrão ISO/IEC 19794-2:2005 especifica o formato dos dados para as representações de impressões digitais baseadas em minúcias (ISO/IEC 19794-2:2005, 2005). Define uma forma genérica de armazenamento de forma que possa conter informações de uma ou mais amostras de impressões digitais. Esse padrão define informações importantes como: o tipo das minúcias, a posição e a orientação, e ainda especifica a forma que os dados serão armazenados (Araújo, 2015).

Segundo Sanchez-Reillo and Mueller (2015), esse padrão ajuda a promover a interoperabilidade de sistemas, visto que a extração de características de uma imagem digital provenientes de um sistema que é capaz de gerar templates nesse formato permite que templates que seguem o padrão ISO possam ser usados por métodos de casamento de impressão digital diferentes. Esse tipo de padrão costuma ser usado em bases de dados compartilhadas de instituições governamentais, iniciativa privada ou em competições.

O padrão ISO gera arquivo com informações de uma ou mais imagens de impressões digitais. Utiliza, obrigatoriamente, informações do nível 2 da impressão digital (minúcias) e também pode conter dados opcionais como: contagem de cristas e informações das singularidades (nível 2). O cabeçalho desse arquivo contém informações gerais a respeito da imagem,

como: tamanho (largura e altura), resolução e quantidades de impressão digital. Para cada impressão digital o arquivo armazena a qualidade, informações sobre suas minúcias e os dados opcionais.

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

- **Tipo de Minúcia:** uma minúcia pode ser do tipo terminação ou 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 de cada minúcia é gravada em um byte (256 valores), onde cada valor corresponde à $1,40625(360/256)$ graus.
- **Qualidade:** A qualidade da minúcia afeta 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 usada para aumentar a confiabilidade dos métodos de casamento de impressões digitais.

2.4.3 Casamento entre Impressões Digitais

Um método de casamento (do inglês: *Matching*) 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 métodos de casamento atuam diretamente nas imagens em escala de cinza geradas pelos sensores. A maioria deles utiliza como entrada o *template*, adquirido na etapa de extração de características. Com isso, é de essencial importância que o método de extração seja confiável e possa gerar um *template* favorável ao método de casamento.

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), conforme ilustrado na Figura 2.11. No entanto, a maior incidência de erros na comparação ocorre devido aos erros provenientes da etapa de extração. Os métodos 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 (Zhu et al., 2006).

Figura 2.11: Amostras deslocadas, rotacionadas e com ruído. Fonte: próprio autor.



Existem muitos métodos de casamento de digitais propostos na literatura. A maior parte desses métodos não tem dificuldade ao comparar imagens de alta 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 método de checagem de qualidade pode ser usado para que apenas imagens de média e alta qualidade sejam usadas e armazenadas nos bancos de dados. Porém, a ação humana não é viável em sistemas de reconhecimento biométricos autônomos, os quais são cada vez mais presentes no mercado.

Uma análise de erros de falsas rejeições produzidas por vários métodos de *matching* que participaram do FVC2000 mostrou que 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 método de extração de minúcias confiável é de suma importância para todo o processo, principalmente em imagens de baixa qualidade que possuem regiões irrecuperá-

veis, onde o processo de extração precisa identificar essas regiões e retirá-las, adicionando apenas regiões adequadas para o *template*.

2.4.4 Métricas de Erro

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 por meio de um valor denominado *escore*, de modo que quanto maior for o *escore*, maior serão as semelhanças entre duas amostras. A comparação entre duas amostras biométricas do mesmo indivíduo é conhecida como *Genuína*, ou *Verdadeira*. Por outro lado, a comparação entre duas amostras originadas de indivíduos diferentes é conhecida como *Impostor*, ou *Falso*. Um *escore* de uma comparação impostora que excede um limiar N de aceitação gera uma *Falsa Aceitação*, enquanto um *escore* de uma comparação genuína 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.

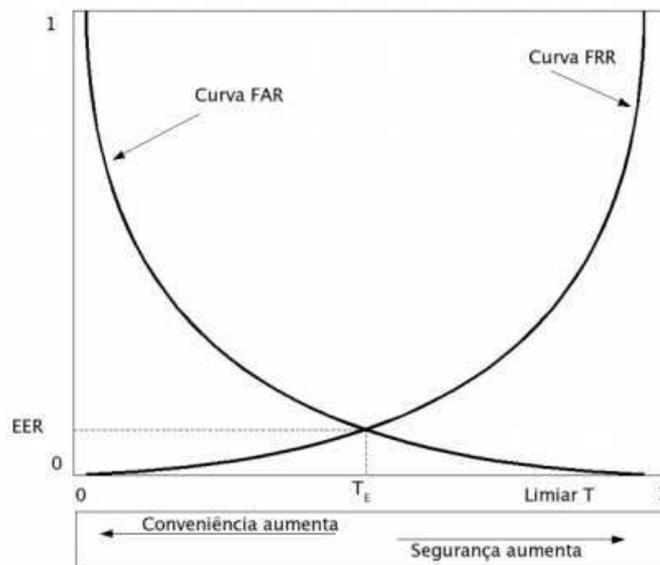
De acordo com Ross et al. (2006), as taxas FAR e FRR podem ser formalizadas pelas Equações a seguir:

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

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

Onde $p(s|impostor)$ e $p(s|genuino)$ representam distribuições de probabilidade de um escore s sobre condições de genuíno e impostor, respectivamente, e η 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 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 et al. (2006).



É importante destacar que o ajuste do limiar permite a calibragem do sistema, mas também implica consequências opostas. Sistemas onde falhas 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 poderão 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.

2.5 Competição de Verificação de Impressões Digitais

A Competição de Verificação de Impressões Digitais (do inglês, *Fingerprint Verification Competition* - (FVC) 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 pelas seguintes instituições: *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 métodos e pudessem observar o estado da arte na área de reconhecimento de impressões digitais.

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, em que os mesmos não possuem acesso ao conjunto de dados, que permanece isolado. Além disso, a FVC-onGoing não é voltada apenas para métodos de verificação de impressões digitais, são avaliados métodos de extração de orientação de imagens, extração de minúcias e indexação de impressões digitais.

2.6 Imagens e Processamento Digital de Imagens

Uma imagem monocromática é uma função $f(x, y)$, em que 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 (Marques and Vieira Neto, 1999). 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: Notação 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 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 o campo 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.

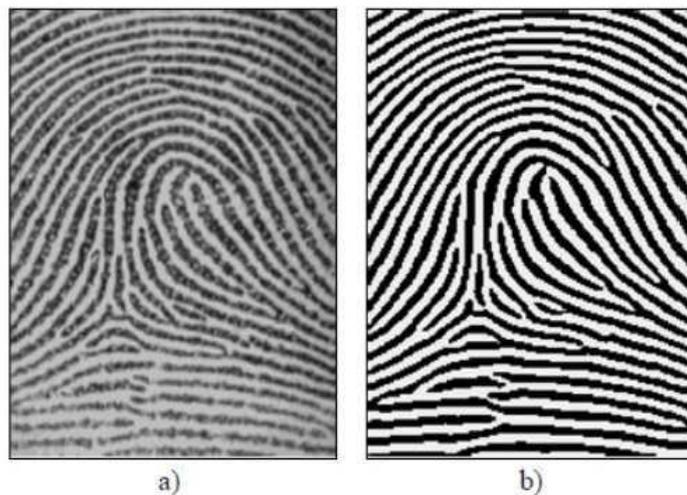
O Processamento Digital de Imagens é altamente multidisciplinar (Batista, 2005), e tem relações muito próximas com as áreas de Computação Gráfica (a qual consiste em sintetizar imagens a partir de dados) e Visão Computacional (a qual consiste em analisar o conteúdo de imagens, produzindo imagens). Muitas 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.

2.6.1 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 (ver Figura 2.14).

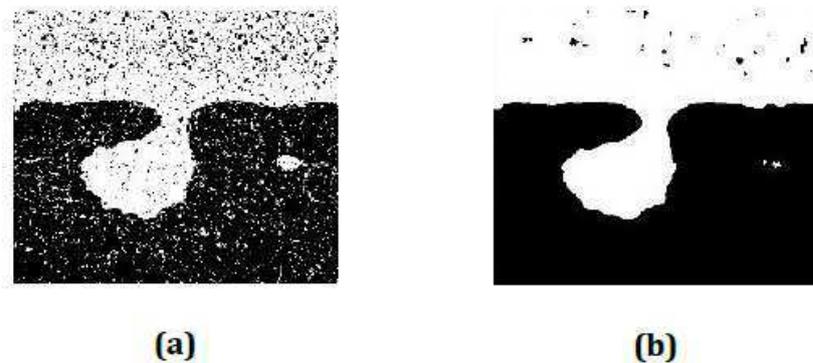
Figura 2.14: Exemplo de Binarização: (a) imagem original, (b) resultado da aplicação da binarização. Fonte: próprio autor.



2.6.2 Filtro da Mediana

A mediana é um filtro de processamento digital de imagens comumente utilizado para redução de ruído, contribuindo em certos casos para uma análise mais precisa da informação. Nesta técnica, o nível de cinza do pixel central da janela é substituído pela mediana dos pixels situados em sua vizinhança (Marques and Vieira Neto, 1999), como mostrado na Figura 2.15.

Figura 2.15: Exemplo de aplicação da mediana: (a) Imagem original, (b) Resultado após a aplicação do filtro da mediana de dimensões 5x5



A mediana m de um conjunto de n elementos é o valor tal que metade dos n elementos do conjunto situem-se abaixo de m e a outra metade acima de m . Quando n é ímpar, a mediana é o próprio elemento central do conjunto ordenado. Nos casos em que n é par, a mediana é calculada pela média aritmética dos dois elementos mais próximos do centro. A ordenação (*sorting*) constitui uma etapa de tempo de processamento relativamente alto, apesar de inúmeros métodos eficientes existentes na literatura (Marques and Vieira Neto, 1999).

2.6.3 Segmentação

Uma das etapas mais importantes em um AFIS é a segmentação da impressão digital, constitui-se na decomposição de uma imagem nos seus componentes. Uma imagem capturada de impressão digital geralmente é composta por uma região originada a partir do contato de um dedo com o sensor, que constitui a Região de interesse (*Region of Interest - ROI*), e região externa à impressão digital.

O objetivo da segmentação é delimitar a ROI. Uma segmentação eficiente é importante para a confiabilidade na etapa de extração de características. A maioria dos métodos de extração gera um elevado número de falsas características quando são aplicados em áreas de ruído ou em regiões que não fazem parte da ROI. Com isso, a segmentação busca descartar essas regiões, reduzindo assim o número de falsas características extraídas (Bazen and Gerez, 2001). A Figura 2.16 mostra um exemplo de segmentação de uma imagem de impressão digital.

Figura 2.16: Segmentação de impressão digital. Fonte: próprio autor.



2.7 Coeficiente de Similaridade de Jaccard

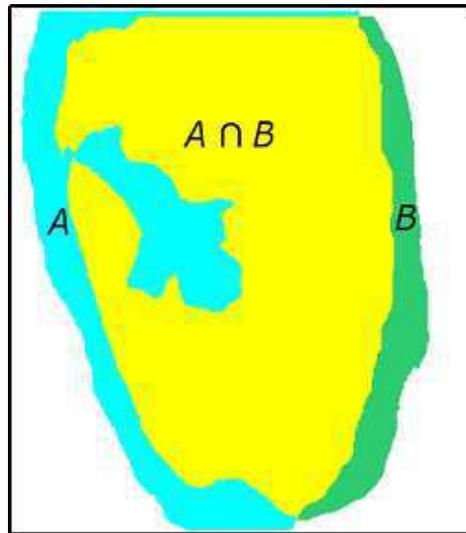
O coeficiente de similaridade de Jaccard é uma técnica utilizada para medir o grau de similaridade entre amostras finitas no processamento de dados. O coeficiente de Jaccard é obtido por meio da divisão entre o número de características que são comuns a todas as amostras e o número total de características, 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 imagem de impressão digital, ver Figura 2.17, 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 existir pixels em comum nas regiões ($|A \cap B| = 0$).

Figura 2.17: Sobreposição de duas regiões de interesse de uma mesma impressão digital.

Fonte: próprio autor



2.8 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 método (*foreground* detectado/classificado incorretamente). Seja E_b o número de pixels marcados como *background* por especialistas e estimados como *foreground* por algum método de segmentação (*background* detectado/classificado erroneamente). O erro total médio por imagem é mostrado na Eq.2.4

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

2.9 Filtros de Gabor

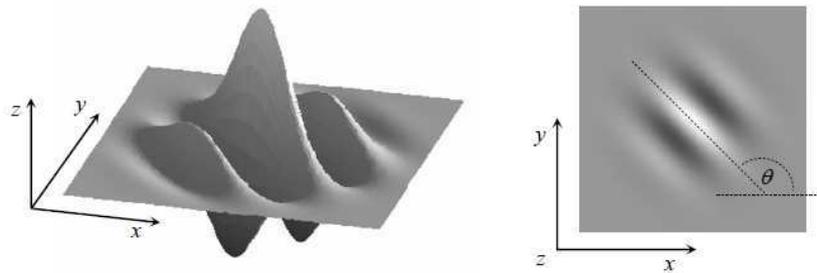
O Filtro de Gabor é um filtro linear frequentemente empregado para detecção de bordas e realce de imagens. Ele é seletivo tanto em frequência quanto em orientação e tem resolução conjunta ótima nos domínios espaciais e frequenciais (Turrone et al., 2012). Como mostrado

na Figura 2.18, um filtro de Gabor é definido por uma onda senoidal plana (o segundo termo da Eq. (2.5) moduada por uma curva Gaussiana (o primeiro termo da Eq. (2.5)). O filtro de Gabor bidimensional tem a seguinte fórmula:

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

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

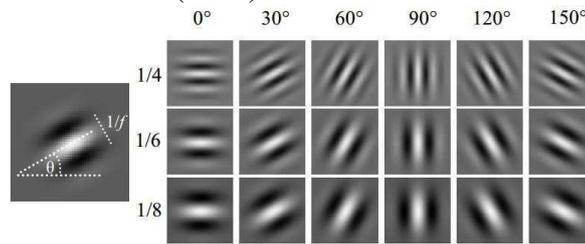
Figura 2.18: Representação gráfica (visão lateral e superior) do filtro de Gabor. Fonte: Turroni et al. (2012).



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

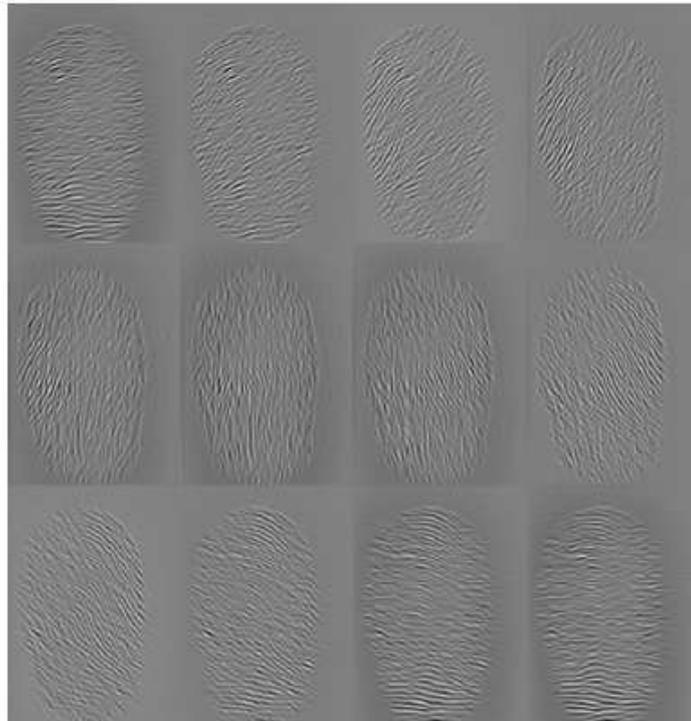
Para tornar o método de realce mais rápido, ao invés de calcular o filtro ideal para cada pixel em tempo de execução, um conjunto $\{g_{i,j}(x, y) | i = 1..n, j = 1..n\}$ de filtros é previamente criado e armazenado, em que n_o é o número de orientações $\{\theta_i | i = 1..n_o\}$ e n_f é o número de frequências $\{f_j | j = 1..n_f\}$. Então, cada pixel $[x, y]$ é convoluído com o filtro $g_{i,j}(x, y)$. A Figura 2.19 mostra um exemplo de um conjunto de filtros com $n_o = 6$ e $n_f = 3$.

Figura 2.19: Um conjunto de filtros de Gabor com seis orientações θ (colunas) e 3 frequências f (linhas). Fonte: Turroni et al. (2012)



Cada convolução com uma máscara de Gabor destaca uma orientação diferente na imagem da digital, variando-se a orientação do filtro de 0 a π . Após normalizar (entre 0 a 255) os valores absolutos da imagem resultante da aplicação da máscara de Gabor é possível visualizar todas as regiões que se destacam com uma determinada máscara. A Figura 2.20 ilustra este processo, usando um passo de $\frac{\pi}{12}$ radianos:

Figura 2.20: Convolução com filtros de Gabor de diferentes orientações. Fonte: próprio autor.

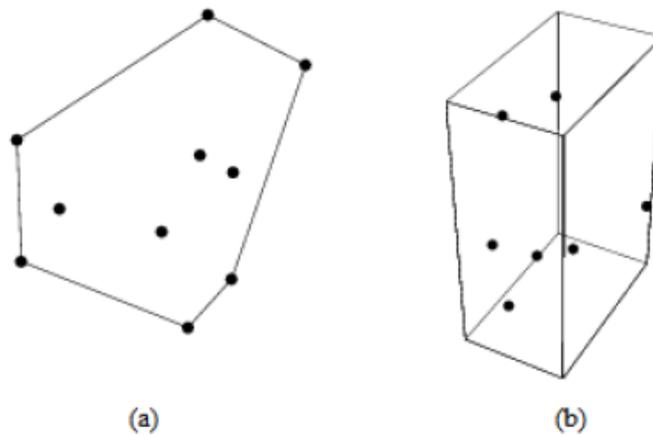


2.10 Envoltória Convexa

O problema da envoltória convexa (do inglês: *Convex Hull*) foi um dos primeiros problemas do campo de geometria computacional estudado, do ponto de vista de complexidade computacional. A função 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 and Seidel, 1986).

A Figura 2.21 exemplifica a aplicação do método em conjuntos de pontos em espaços dimensionais variados. A Figura 2.21(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 2.21(b).

Figura 2.21: Exemplos da função envoltória convexa aplicada em: a) pontos em um plano bidimensional e b) pontos em um espaço tridimensional. Fonte: Weisstein (2016)



2.11 Medida de Assimetria

Em uma distribuição simétrica, cada momento de ordem ímpar sobre a média (caso exista) é igual a zero. Qualquer momento que não seja zero pode, portanto, ser considerado como uma medida da assimetria ou obliquidade da distribuição (Harald, 1946). O coeficiente de

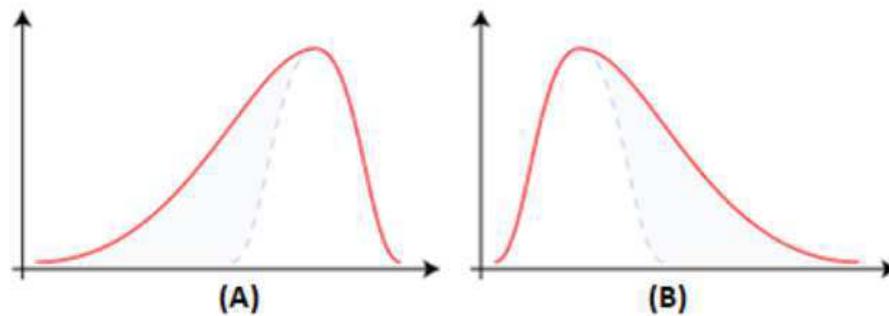
assimetria (*skewness*) é definido por:

$$\gamma = \frac{\mu_3}{\sigma^3} \quad (2.6)$$

onde μ_3 é o terceiro momento central e σ é o desvio padrão. O terceiro momento central é a medida de assimetria mais simples e a divisão por σ^3 é realizada para reduzir à dimensão zero e construir uma medida absoluta.

Figura 2.22: Representação gráfica de uma distribuição. (A) Distribuição com cauda para esquerda (assimetria negativa). (B) Distribuição com cauda para direita (assimetria positiva).

Fonte: próprio autor



Capítulo 3

Trabalhos Relacionados

Nessa seção são revisados trabalhos relacionados à pesquisa proposta. Primeiramente, são apresentados trabalhos que realizam a segmentação de impressões digitais. Em seguida, são relacionados métodos de realce (*enhancement*) de impressões digitais, assim como pesquisas que realizam comparações entre métodos de pré-processamento e extração de características de impressões digitais.

3.1 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 (P-B), baseada em blocos (B-B) e baseada em grafos (G-B). Um método 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 métodos P-B obtiveram sucesso em segmentação de impressões digitais. Bazen and 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 compu-

tacional. 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 terem publicado o seu trabalho, Rojas et al. (2006) propuseram uma melhoria ao método que tratava os casos em que as classes poderiam não ser linearmente separáveis, resultando em falhas no classificador linear. Esse método 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 métodos 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 métodos 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 dos 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 and Maltoni (1997) em 1997, em que 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. (2001a) 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 métodos 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 são associados com um peso, $w(i, j)$, que pode ser caracterizado como uma propriedade entre nós conectados (Msiza et al., 2011). Os métodos de segmentação G-B não são tão eficazes com relação à segmentação de impressões digitais, assim, não entraremos em muitos detalhes dessa abordagem.

Os métodos de segmentação classificados com pertencentes ao estado-da-arte recentemente são discutidos nos parágrafos abaixo.

Sankaran et al. (2017) propuseram um novo método para segmentar impressões digitais latentes utilizando métodos 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% em bases de dados.

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 métodos em um conjunto de 160 imagens de impressões digitais. Os resultados apontaram os lados positivos e negativos de cada um dos métodos.

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). Além disso eles também fizeram a segmentação manual de 10560 imagens, e conduziram um método de comparação sistemático para comparar o método de segmentação deles com outros métodos considerados os mais citados na área de segmentação de impressão digitais. Seus resultados mostram que o método desenvolvido é 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 métodos utilizando este gabarito.

Thai and 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. Thai et al. (2016). Os resultados mostraram 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 proposto nesta pesquisa de doutorado será comparado com o G3PD, FDB e outros métodos presentes nos trabalhos de Bazen and Gerez (2001) Shen et al. (2001a), Wu et al. (2007) e Chikkerur et al. (2007), que foram incluídos no sistema de comparação desenvolvido por Thai et al. (2016).

Um 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, como nas pesquisas de Sherlock et al. (1994), Chikkerur et al. (2007), Jirachaweng and 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 na abordagem proposta nesta pesquisa de doutorado. Os filtros de Gabor são a base para o método proposto, tanto de segmentação quanto de realce, e serão descritos com mais detalhes na seção seguinte.

Existem alguns trabalhos que utilizam redes neurais convolucionais para a segmentação de imagens de impressão digital. O trabalho apresentado por Stojanović et al. (2016) utiliza uma CNN treinada com amostras de imagens para classifica-las como pertencentes ao ROI ou ao plano de fundo. Para esse problema, eles utilizaram duas arquiteturas de CNN da literatura, projetadas para problemas de classificação: AlexNet, projetado para reconhecimento de objetos e LeNet, projetado para reconhecimento de dígitos manuscritos.

No trabalho de Tang et al. (2017) é apresentada a FingerNet, uma arquitetura que, entre outras etapas, realiza a segmentação da impressão digital. Porém, não foi apresentado resultados de acurácia da segmentação. A abordagem proposta por Nguyen et al. (2018) apresenta uma estrutura de segmentação latente totalmente automática, chamado SegFinNet, que processa toda a imagem de entrada de uma só vez e pode gerar várias regiões de interesse na imagem. Além desses trabalhos, também podemos citar Zhu et al. (2017), Ezeobijesi and Bhanu (2017) e Khan and Wani (2019). Todos esses trabalhos abordam a segmentação em imagens de impressão digital latentes e não fazem parte do foco desta tese.

3.2 Trabalhos Relacionados sobre Avaliação de Qualidade

A avaliação da qualidade das impressões digitais atraiu esforços da área acadêmica e industrial. Os estudos existentes podem ser classificados em três categorias: (i) abordagens baseadas na segmentação; (ii) abordagens baseadas em características únicas; e (iii) soluções realizadas usando fusão multi-característica, que pode ser alcançada através de uma fusão ou classificação linear (Yao et al., 2016).

Abordagens baseadas na segmentação. As abordagens da primeira categoria podem representar a qualidade da área de primeiro plano ou segmentar o primeiro plano da imagem no início. Shen et al. (2001b) propôs um método baseado em filtros de Gabor. Cada bloco da imagem é filtrado usando um filtro Gabor com direções diferentes de m . Se um bloco tiver alta qualidade (ou seja, forte direção do relevo), as respostas de alguns filtros são maiores que as outras. Em blocos de baixa qualidade ou blocos de segundo plano, as respostas do filtro m são semelhantes. O desvio padrão das respostas do filtro m é então usado para determinar a qualidade de cada bloco ("bom" ou "ruim"). O índice de qualidade (QI) da imagem inteira é finalmente calculado como a porcentagem de blocos de primeiro plano marcados como "bons". Se QI for menor que um limite predefinido, a imagem será rejeitada. Imagens de baixa qualidade são adicionalmente categorizadas como "borradas" ou "secas" (Shen et al., 2001b).

Yao et al. (2015) propôs uma abordagem com modelo de minúcias apenas usando envoltória convexa e triangulação de Delaunay. Eles são adaptados para medir a área de uma região informativa. Esse algoritmo é, portanto, dependente de uma operação de extração de minúcias na impressão digital.

Abordagens baseadas em única característica. Chen et al. (2005) estimaram o anel de espectro de potência com funções Butterworth em vez de observar a informação de pixel diretamente na imagem do espectro. Lee et al. (2005) revisou abordagens baseadas no desvio padrão local, o contraste direcional do bloco local e os recursos do Gabor. Um recurso foi proposto pela análise do espectro de Fourier de uma imagem de impressão digital. Sua abordagem depende da informação de pixels da imagem do espectro de Fourier, que é uma medida flutuante para diferentes tipos de configurações de imagem.

Métodos de fusão de vários recursos. O trabalho apresentado por Lim et al. (2002)

é um exemplo desta categoria.. Eles calculam os seguintes recursos em cada bloco: Nível de Certeza de Orientação (OCL), frequência da crista, espessura da nervura e razão entre a espessura da crista e o vale. Os blocos são então rotulados como "bons", "indeterminados", "ruins" ou "em branco", definindo limites para os quatro recursos. Uma pontuação de qualidade local SL é finalmente calculada com base no número total de blocos de imagem de qualidade "boa", "indeterminada" e "ruim" na imagem.

A métrica de qualidade mais utilizada na literatura é a Qualidade de Imagem de Impressão Digital NIST (*NIST Fingerprint Image Quality - NFIQ*) foi proposta por Barringer and Tabassi (2011). Abordagem emprega o recurso de 11 dimensões (explorando várias características, como fluxo de orientação da crista, curvatura da crista local e contraste local) para estimar uma pontuação correspondente e classificar os resultados em cinco níveis por meio de um modelo treinado de rede neural.

O trabalho apresentado por Ezeobiejiesi and Bhanu (2018) avalia a qualidade da imagem da impressão digital latente como um problema de classificação e resolve usando uma rede neural profunda.

3.3 Trabalhos Relacionados sobre o Tema Realce

A maior parte dos trabalhos sobre métodos de realce e melhoria de qualidade de impressões digitais exploram informações contextuais, (Maltoni et al., 2009). O contexto é normalmente representado pela orientação, frequência e de 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 tem ambas as propriedades de frequência e orientação seletiva e tem 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 and Areekul (2007) e Chikkerur et al. (2007).

No trabalho de Shen and Eshera (2004), são descritos alguns métodos para extrair características de impressões digitais por meio de um mapeamento dessas características no

domínio do espaço, utilizando técnicas de pré-processamento, direção e espessura de *cristas*, realce e detecção de minúcias.

O trabalho apresentado por Raff (2018) utiliza redes neurais convolucionais para realçar a imagem de impressão digital. O autor utiliza imagens sintéticas de impressão digital para treinar seu modelo e testa sua acurácia nos bancos disponibilizados pelo FVC. O desempenho foi avaliado rodando o modelo em GPU, não sendo apresentado o tempo em CPU.

O método de realce apresentado por Turroni et al. (2012) mostra-se bastante eficiente, pois consegue recuperar cristas falhas e eliminar ruídos na imagem. Com isso, são extraídas menos falsas minúcias e melhora o desempenho dos métodos de casamento. Seu método consiste em uma filtragem contextual de acordo com utilização de Gabor iterativo. De acordo com seu trabalho, o método 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 será 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 Eq.3.1 mostra o valor do pixel em determinada posição da imagem.

$$p(x, y) = \max(|V_1(x, y)|, |V_2(x, y)|, \dots, |V_{24}(x, y)|) \quad (3.1)$$

Posteriormente é criada uma imagem de homogeneidade $H = \{h_{x,y} | x = 1..w, y = 1..h\}$ que tem como objetivo retirar discontinuidades da imagem de entrada, visto que mudanças repentinas na orientação e frequência em regiões pequenas não devem existir, exceto em re-

giões de singularidade. Verifica-se para cada pixel, a orientação e frequência dos pixels de sua vizinhança, por meio de uma janela de 9x9 pixels. Para regiões bem definidas, onde a fluidez das cristas e dos 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 método escolhe os pixels que serão realçados utilizando um critério de classificação. A ideia é selecionar uma porcentagem de pixels de alta qualidade, ou seja, regiões em que a máscara de Gabor respondeu melhor (positiva ou negativa) 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 (Equação 3.2), selecionando os melhores pixels.

$$F_{x,y} = c_{x,y} \cdot h_{x,y} \cdot r_{x,y} \quad (3.2)$$

em que $R = \{r_{x,y} | x = 1..w, y = 1..h\}$ é uma matriz de seleção na qual $0 < r_{x,y} \leq 1$. A matrix 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 método ordena os pixels da imagem F e escolhe os pixels com maior resposta negativa e os pixels com maior resposta positiva, por meio de um valor percentual γ , e os coloca em dois conjuntos A e B correspondendo aos cristas e vales, respectivamente. Os conjuntos podem ser definidos pelas seguintes equações.

$$A = \{I_{x,y} | rank(f_{x,y}) \leq \gamma \cdot |F|\} \quad (3.3)$$

$$B = \{I_{x,y} | rank(f_{x,y}) \geq (1 - \gamma) \cdot |F|\} \quad (3.4)$$

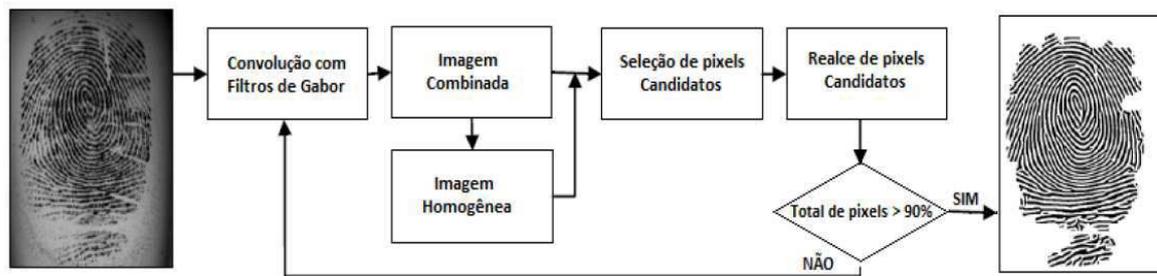
Os pixels contidos nos conjuntos A e B serão realçados da seguinte maneira:

$$\Delta_{x,y} = \begin{cases} 0 & , se I_{x,y} \in A \\ 255 & , se I_{x,y} \in B \end{cases} \quad (3.5)$$

$$I_{x,y} = I_{x,y} \cdot (1 - \epsilon) + \Delta_{x,y} \cdot \epsilon \quad (3.6)$$

em que $0 < \epsilon \leq 1$ controla a intensidade do realce. O método utiliza $\epsilon = 0,7$. O método 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 sofreu realce. A Figura 3.1 mostra as etapas realizadas no método de realce criado por Turrone et al. (2012).

Figura 3.1: Etapas do processo de realce de imagens de impressões digitais proposto por Turrone et al. Fonte: (Turrone et al., 2012)



A Figura 3.2 mostra o resultado do processo aplicado pelo método de Turrone et al. (2012) sobre uma imagem de baixa qualidade.

Figura 3.2: Evolução de uma imagem ruidosa de impressão digital durante o processo iterativo de realce. O realce iterativo ocorre da esquerda para a direita e a cada iteração mais regiões da imagem são recuperadas. Fonte: (Turrone et al., 2012)



Apesar de mostrar-se eficiente em relação à recuperação das cristas e vales, o método de Turrone possui algumas deficiências em relação a abordagem de aplicação do filtro de Gabor, além de possuir tempo de processamento demasiadamente demorado. Essas falhas foram tratadas e serão apresentadas no capítulo 4.

Capítulo 4

Metodologia

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

4.1 Materiais

4.1.1 Ambiente de Desenvolvimento

Foi utilizada a IDE Visual Studio 2015 com as linguagens de programação C++ e C#. Foi desenvolvido um projeto juntamente com a equipe de desenvolvedores da Vsoft Tecnologia para realizar a manipulação das imagens de impressão digital, aplicação dos métodos, armazenamento e leitura de templates em banco de dados SQLite, verificação de tempo, taxas de erro e plotagem de gráficos.

4.1.2 Bases de Dados

As bases de dados de imagens de impressões digitais utilizadas para avaliar os métodos propostos foram as bases do FVC2000, 2002, 2004 e 2006 (Cappelli et al., 2007). Cada base de dados possui imagens de 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	Óptico	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	Óptico	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	Óptico	288 x 384	100 x 8	10 x 8	500 dpi
	2	Óptico	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	Óptico	640 x 480	100 x 8	10 x 8	500 dpi
	2	Óptico	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
2006	1	Eléctrico	96 x 96	140 x 12	10 x 12	250 dpi
	2	Óptico	400 x 560	140 x 12	10 x 12	569 dpi
	3	Térmico	400 x 500	140 x 12	10 x 12	500 dpi
	4	Sintético	288 x 384	140 x 12	10 x 12	Próximo a 500 dpi

As bases de dados contendo imagens de impressões digitais reais foram obtidas por meio de diferentes sensores e possuem diferentes propriedades. A qualidade varia entre imagens de alta 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).

4.1.3 Hardware

Foram utilizados computadores com processador Intel® Core™ i7-3537U 2.0 GHz, 8GB de memória RAM DDR3, sistema operacional Microsoft® Windows 8.1 de 64 bits. As imagens de impressão digital foram adquiridas por meio de sensores elétricos, ópticos e térmicos.

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 casamento, forma um sistema completo de identificação automática de impressões digitais (AFIS).

Como foi mencionado em capítulos anteriores, a etapa de extração de características depende 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 e corte, possam ser removidas. Dessa forma, foi desenvolvido um método que realiza diversas etapas para melhoria da qualidade da imagem e posterior extração de informações, visando reduzir os erros na identificação de indivíduos. O método pode ser dividido nas seguintes etapas (4.1):

- Processo de realce da imagem de impressão digital;
 - Pré-processamento da imagem de impressão digital
 - Convolução Gabor adaptativo
 - Segmentação da região de interesse;
 - Avaliação da qualidade da impressão digital;
 - Aplicação a filtragem iterativa por filtros de Gabor;
- Afinamento;
- Localização das minúcias.
- Filtragem das minúcias.

Figura 4.1: Etapas do processo proposto de extração de minúcias em uma imagem de impressão digital. Fonte: próprio autor.

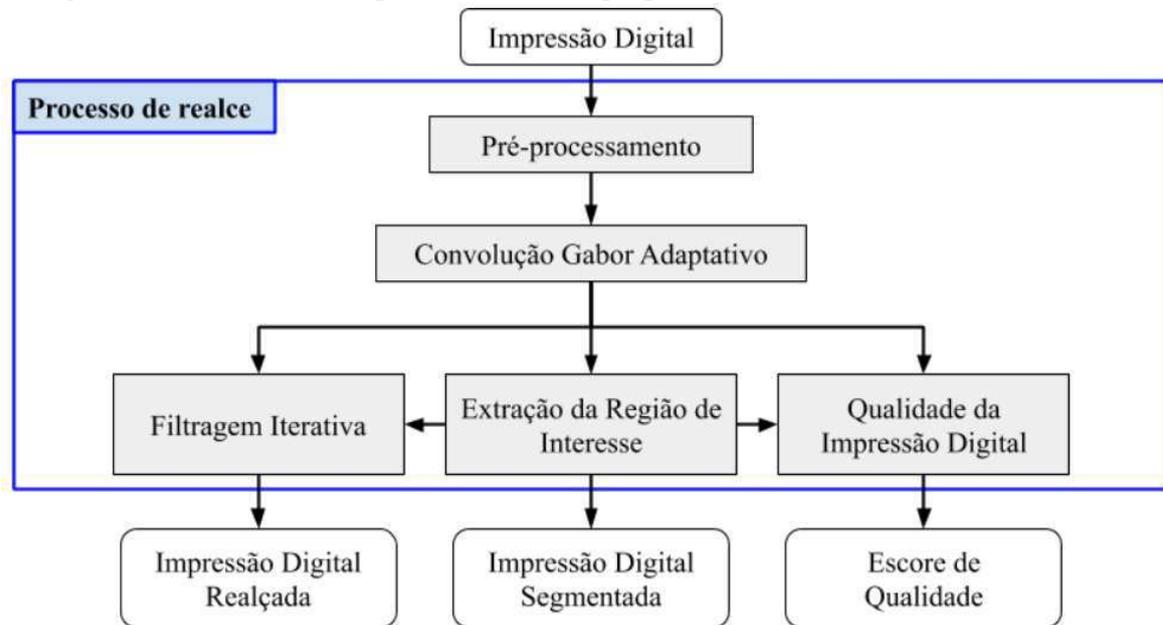


Observando a literatura notou-se que algumas dessas etapas já possuem métodos bastante consolidados e aceitos por toda a comunidade. São as etapas de pré-processamento, afinamento, localização e filtragem das minúcias. Dessa forma, para essas etapas foi utilizado o que já existe na literatura e apenas uma breve explicação sobre os passos será dada. O foco, portanto, deste trabalho está na **melhoria das etapas de segmentação e realce da impressão digital, além da avaliação da qualidade da impressão digital**, uma vez que as mesmas ainda concentram grande parte dos erros de identificação de indivíduos. Nas próximas seções cada uma das etapas relevantes a esta pesquisa é apresentada e detalhada.

4.3 Processo de realce da imagem de impressão digital

A abordagem proposta para a extração de características da imagem de impressão digital é a utilização de convoluções com máscaras de Gabor não só para a realização do realce, mas também para a extração da região de interesse e a avaliação do escore de qualidade. O fluxograma dos processos é apresentado na Figura 4.2.

Figura 4.2: Etapas do processo proposto de realce da imagem de impressão digital com extração da ROI e escore de qualidade. Fonte: próprio autor.

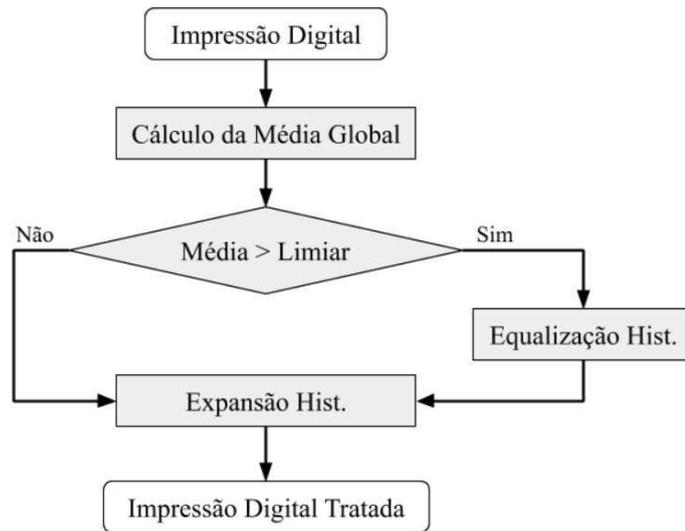


O processo de realce da imagem de impressão digital tem como entrada a imagem original e tem como saída: a imagem da impressão digital realçada, a imagem da impressão digital segmentada pela região de interesse e o escore de qualidade da impressão digital.

4.3.1 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 aumentar 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 se é necessário aplicar ou não a equalização de histograma, foi calculada a média dos valores de níveis de cinza dos pixels para cada imagem, Figura 4.3.

Figura 4.3: Etapas do processo proposto para o pré-processamento das imagens de impressão digital. Fonte: próprio autor.



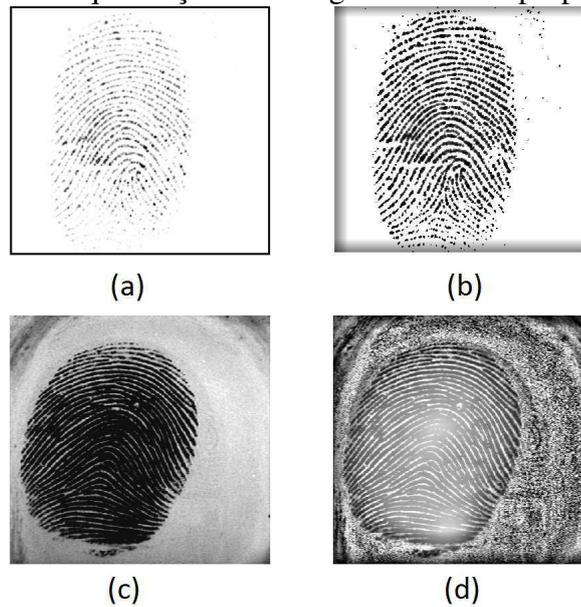
Se uma grande quantidade de pixels tem o nível de cinza próximo da média, a operação de equalização de histograma é aplicada, caso contrário, apenas a operação de expansão de histograma é realizada. Essa quantidade de pixels é determinada por um limiar, que foi empiricamente definido como 80%. Sendo 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 $\pm \frac{n}{2}$ em torno de G . Logo após essa etapa, a operação de expansão de histograma local é aplicada sobre a imagem de impressão digital. Ambas as operações de histograma são realizadas por blocos, cujo tamanho foi definido empiricamente.

A definição do limiar da quantidade de pixels próximo da média foi definida de forma sistemática. Todos os bancos de imagens utilizados foram divididos em uma parte para validação e outra para teste. No banco de validação, o limiar foi variado de 0 a 100. Para cada variação, é calculada a taxa de erro obtida com as minúcias extraídas. O valor que resultar na menor taxa de erro é utilizado nos bancos testes.

A Figura 4.4 mostra duas imagens de impressões digitais de diferentes bases de dados: uma que necessita de equalização de histograma (4.4(a)) e outra que não precisa (4.4(c)). As Figuras 4.4(b,d) mostram o resultado da aplicação de equalização de histograma nas impressões digitais da Figura 4.4(c,d), respectivamente. Observa-se que na Figura 4.4(b), o contraste da imagem é aumentado e a diferença entre *background* e *foreground* é enfatizada,

já para a Figura 4.4(d), uma grande quantidade de ruído é inserida na imagem de saída, dificultando a identificação da região de interesse.

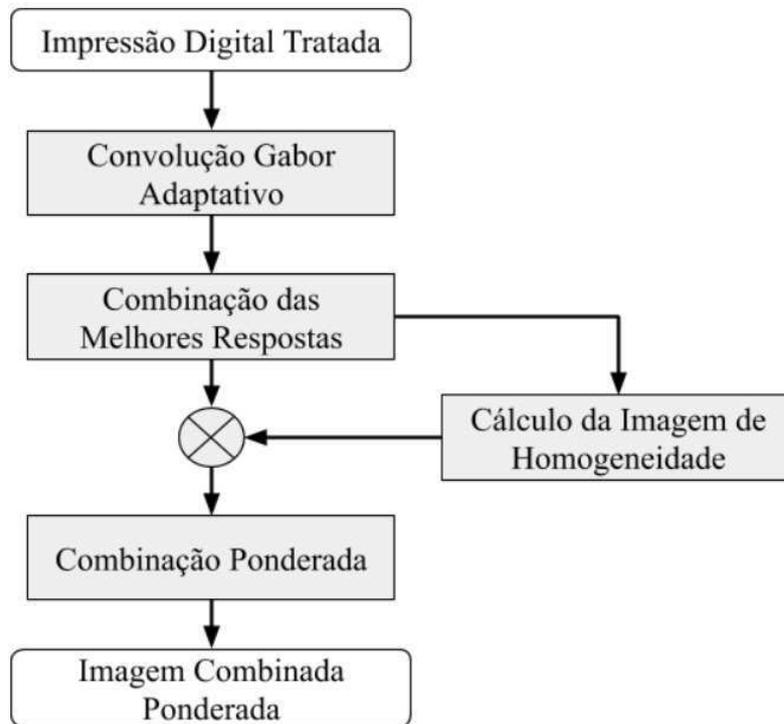
Figura 4.4: Exemplos de equalização de histograma sobre diferentes imagens de impressões digitais. (a) Impressão digital 27_8.bmp da base de dados FVC2002-1, (b) imagem de saída da impressão digital após aplicação da operação de equalização de histograma, (c) Impressão digital 5_7.bmp da base de dados FVC2000-3, (d) imagem de saída da impressão digital 5_7.bmp após aplicação da equalização de histograma. Fonte: próprio autor.



4.3.2 Convolução Gabor Adaptativo

O processo de convolução é dividido em 4 etapas. O fluxograma completo é apresentado na Figura 4.5, seguindo por uma explicação detalhada de cada passo.

Figura 4.5: Etapas do processo de convolução com máscaras de Gabor adaptativa. Fonte: próprio autor.

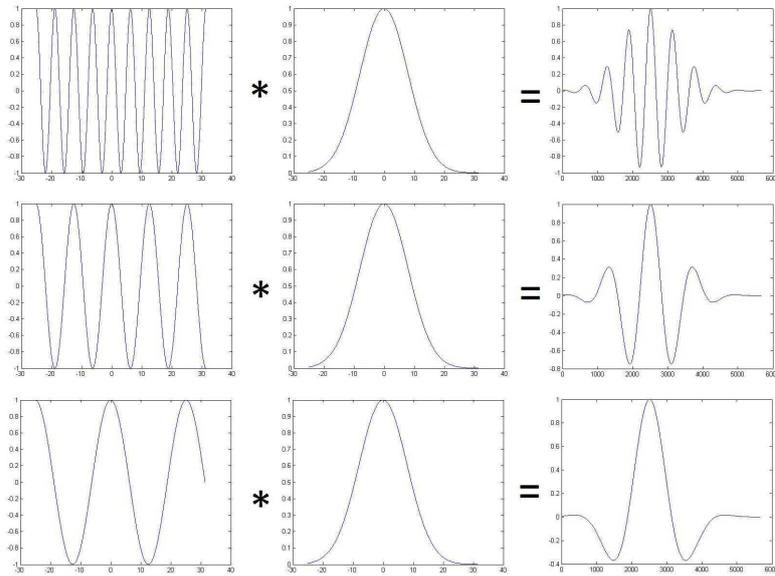


Convolução com um banco de máscaras de Gabor adaptativas

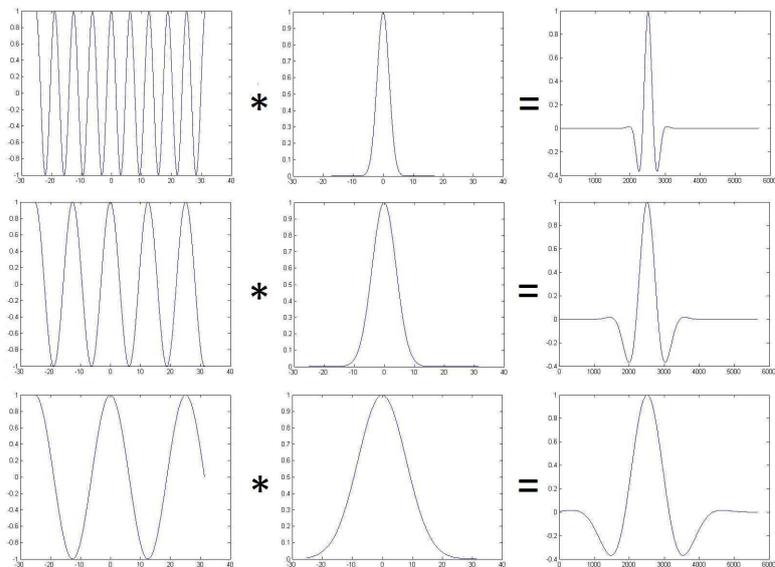
Após a etapa de pre-processamento, são definidos parâmetros para a construção de n máscaras de Gabor para a convolução com a imagem de impressão digital. Esses parâmetros foram definidos como $n_o = 8$ para a orientação e $n_f = 3$ para a frequência, com o objetivo de reproduzir a quantidade de máscaras utilizadas no trabalho de Turrone et al. (2012). A diferença entre as máscaras utilizadas por Turrone e as utilizadas nessa presente pesquisa é o desvio padrão que aqui é definido dinamicamente. Enquanto Turrone et al. (2012) e Hong et al. (1998) usam um valor fixo de σ_x e σ_y , o método proposto determina o desvio padrão de acordo com a frequência f da máscara. A Figura 4.6 mostra os sinais gerados pela Eq. 2.5 usando desvio padrão fixo e diferentes frequências.

Figura 4.6: Sinais de saída do filtro de Gabor utilizando frequências diferentes e σ fixo.

Fonte: próprio autor.



A Figura 4.7 mostra os sinais de Gabor gerados utilizando o desvio padrão baseado nos valores de frequência.

Figura 4.7: Sinal de saída do filtro de Gabor utilizando frequências diferentes e σ definido dinamicamente de forma adaptativa. Fonte: próprio autor.

Como pode ser observado, existe uma diferença entre as duas abordagens, na Figura 4.6 os sinais de saída diferem devido às diversas frequências testadas, enquanto que na Figura

4.7 os sinais de saída são bastante similares mesmo com frequências diferentes.

Notou-se que ao utilizar um σ 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 σ fixo, o que acarreta maior dificuldade para casar os padrões e obter boas respostas com máscaras de frequência elevada.

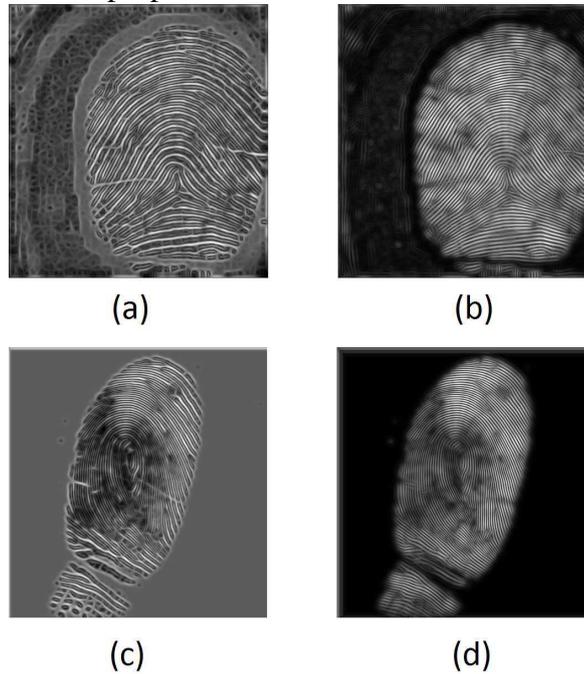
Combinação das melhores respostas de Gabor

Após a criação das máscaras de Gabor, a imagem de impressão digital é convoluída com todas as máscaras. O conjunto das imagens resultantes das convoluções é utilizado para formar a imagem combinada, em que cada pixel é a resposta máxima dentre os pixels na mesma posição das imagens do conjunto. (Figura 4.10c), i.e.:

$$C_{i,j} = \max(|g_{i,j}^1|, |g_{i,j}^2|, \dots, |g_{i,j}^n|) \quad (4.1)$$

Os valores dos pixels da imagem combinada são normalizados para a faixa de valores [0,1], em que 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 4.8(a,b) são as imagens combinadas resultantes da imagem de impressão digital 11_5.bmp da base de dados FVC2000-3 DBA. Na Figura 4.8(a) foram utilizados σ_x e σ_y fixos, com valores definidos por Hong e Cappeli, enquanto que na Figura 4.8(b), foi utilizado o filtro de Gabor adaptativo desenvolvido nesta pesquisa com σ_x e σ_y definidos dinamicamente. As Figuras.4.8(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 por meio da convolução com o filtro de Gabor adaptativo (Figuras 4.8(b,d)) possuem mais destaque na região de *foreground* que na região de *background* quando comparadas com as imagens resultantes da aplicação de filtros de Gabor com σ fixo, esse é exatamente o propósito desta abordagem, facilitar a separação entre *foreground* e *background*.

Figura 4.8: Imagens Combinadas utilizando σ fixo (a,c) e σ definido dinamicamente de forma adaptativa (b,d). Fonte: próprio autor.



Cálculo da imagem de homogeneidade

Além dos passos anteriores, também foi utilizado o conceito da imagem de Homogeneidade definida por Turrone et al. (2012). Nessa etapa não foi realizada nenhuma modificação, utilizando o processo descrito pelos autores. 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 por meio do padrão da impressão digital, e mudanças abruptas na orientação e na frequência não devem existir. Isso significa que casos existam essas discontinuidades, 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 m é o tamanho da janela aplicada, p e k estão na faixa entre $[-\frac{m}{2}, +\frac{m}{2}]$. $S_{p,k}$ é a medida de orientação de homogeneidade, que é definida como:

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

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

Então, H é normalizada para ajustar valores no intervalo $[0,1]$. Valores mais baixos denotam menor homogeneidade e vice-versa. A Figura 4.10(d) mostra um exemplo de imagem de homogeneidade. Os pixels mais claros representam região contínua sem heterogeneidade de ângulos.

Combinação ponderada

Após calcular a imagem combinada C e a imagem de homogeneidade H , os pixels com respostas fortes (positivas ou negativas) em C e pertencentes a regiões altamente homogêneas em H são considerados pixels de interesse. A equação abaixo descreve esse processo.

$$p_{i,j} = c_{i,j} \cdot h_{i,j} \quad (4.4)$$

Seja $P = \{p_{x,y} | x = 1..w, y = 1..h\}$, a imagem resultante de uma multiplicação de pixels entre os C e H . Quanto maior o valor do pixel absoluto, maior a confiança que é uma região bem definida e de boa qualidade. O sinal do valor do pixel determina se corresponde a uma crista ou vale, valores negativos e positivos, respectivamente.

A partir da imagem combinada ponderada P são realizados os processos de definição da região de interesse, realce da imagem de impressão digital e avaliação da qualidade da impressão digital.

4.3.3 Segmentação da Região de Interesse

A primeira etapa do processo de realce da imagem de impressão digital 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 método de ROI são descritos, assim como a metodologia utilizada para avaliação e comparação com alguns trabalhos relacionados.

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 suprimir informações de características verdadeiras.

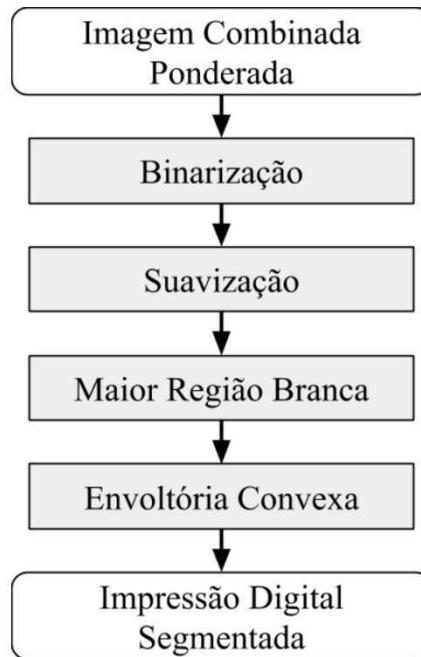
Existem basicamente dois pontos de vista em relação à segmentação de impressões digitais, que não estão muito claros na literatura. O primeiro conceito e também o mais aceito é a divisão da impressão digital em *background* e *foreground*. O outro ponto de vista consiste na seleção das regiões da imagem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

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 é apresentado na Figura 4.9, seguido por uma explicação detalhada dos passos individuais.

Figura 4.9: Fluxograma com todos os passos realizados no método de segmentação proposto.

Fonte: próprio autor.



- Binarização

Logo após, a imagem combinada ponderada é normalizada entre 0 e 255 e é aplicado um limiar para delinear a região de interesse (ROI), assim, caso o valor do pixel seja maior que o limiar, o mesmo pertence à ROI (Figura 4.10(f)), como mostrado abaixo:

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

O limiar foi definido em 6, 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

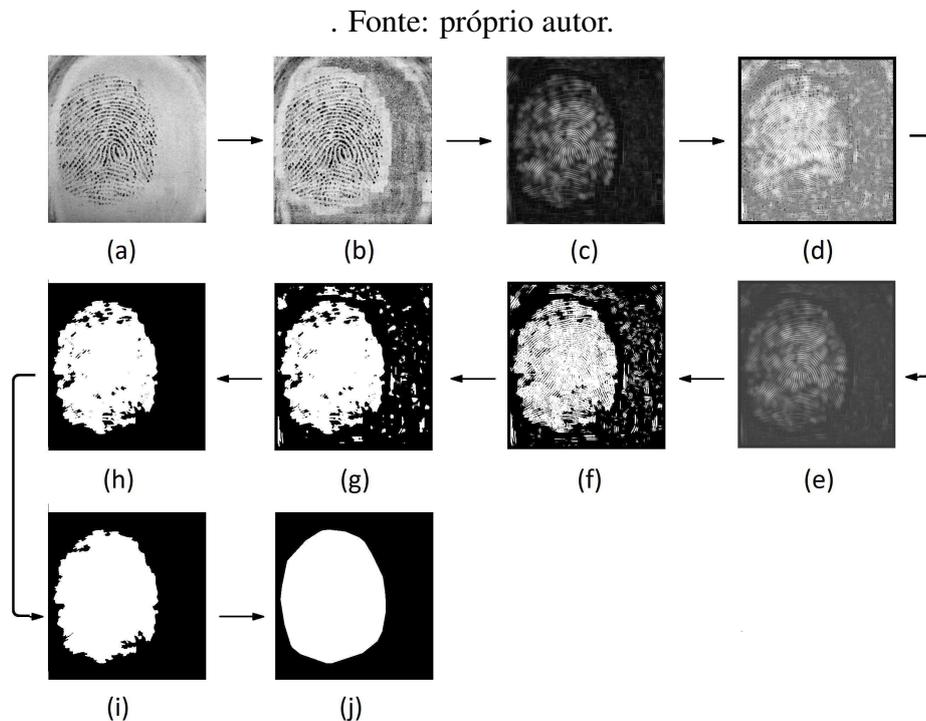
Após esta etapa, é aplicado o filtro da mediana para remover ruídos e conectar cristas e vales em uma única região. O tamanho da máscara de mediana foi definido em 5x5 depois de ser realizada uma avaliação empírica. Notou-se que máscaras maiores removiam regiões importantes da imagem de impressão digital, enquanto máscaras menores deixavam uma quantidade significativa de ruído (Figura 4.10(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 4.10(h)).

- Limpar segmentação e Envoltória Convexa (*Convex Hull*)

Por fim, se existem espaços presentes na região interna da imagem resultante, os mesmos são preenchidos (Figura 4.10(i)) e para finalizar é aplicado o envoltória convexa, obtendo a ROI (Figura 4.10(j)). A Figura 4.10 mostra todas as etapas do método proposto. A área branca indica a região de interesse da impressão digital.

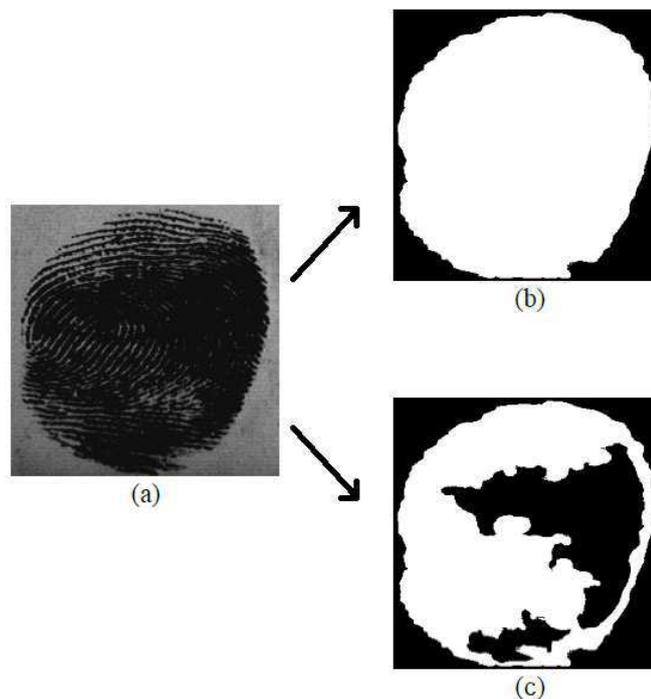


Conforme foi mencionado no início do capítulo, existem dois conceitos distintos para a segmentação de impressões digitais. O método mostrado acima com todas as etapas descritas se encaixa no conceito de segmentação em *background* e *foreground*, e será utilizado para avaliar a segmentação por meio do 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 será utilizado o conceito de ROI que retira as regiões irrecuperáveis da

imagem, dessa forma será utilizada a imagem resultante mostrada na Figura 4.10(i), sem a retirada dos espaços contidos na imagem e a utilização da envoltória convexa.

A Figura 4.11 mostra a diferença entre os dois conceitos mencionados. Tendo a Figura 4.11(a) como uma imagem de entrada de baixa qualidade com algumas regiões irrecuperáveis, são extraídas as duas regiões de interesse diferentes. A Figura 4.11(b) baseia-se no conceito puro de segmentação, onde a imagem é separada em *background* e *foreground*. Na Figura 4.11(c) o método de segmentação exclui as regiões de baixa qualidade, o que posteriormente irá resultar em uma menor quantidade de falsas minúcias.

Figura 4.11: Imagem de impressão digital (a) segmentada de duas formas utilizando diferentes conceitos: (b) imagem separada em região pertencente à impressão digital e (c) região recuperável impressão digital. Fonte: próprio autor.



Validação do Método de Segmentação

As bases de dados de imagens de impressões digitais utilizadas para avaliar o método de segmentação proposto foram as bases de dados do FVC2000, FVC2002 e FVC2004 (Cappelli et al., 2007).

Para cada base de dados foi utilizado o conjunto B de imagens para treinar os parâmetros

e o conjunto A para testar o método. 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 imagens de 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 método de segmentação e assim, comparar com os métodos 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 Eq. 2.4. Dessa forma, buscando avaliar o método proposto nesta pesquisa, foi utilizado o método de comparação de Thai et al. (2016). Além disso, devido a algumas inconsistências, explicadas mais adiante, no método de comparação de Thai et al., também foi utilizado o método de comparação pelo índice de Jaccard.

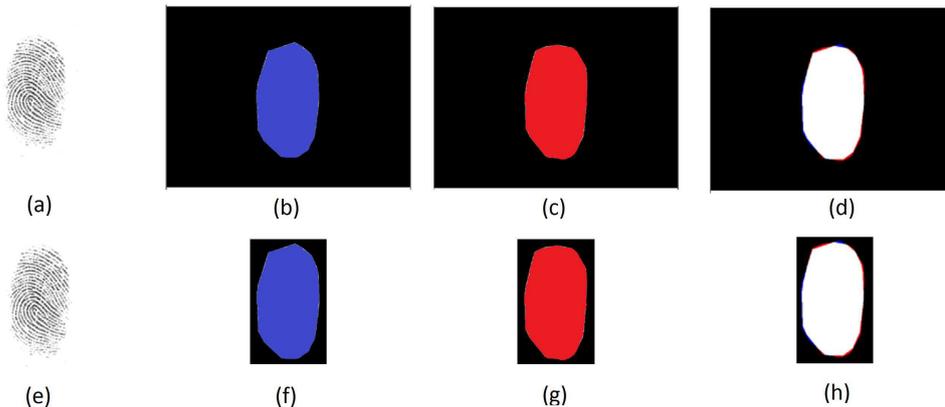
Existem basicamente duas razões para a escolha desses dois métodos distintos de comparação. Primeiramente, o método proposto por Thai et al. (2016) é utilizado no trabalho dos mesmos para comparar 5 trabalhos bastante conhecidos na literatura e também utilizado por Thai and Gottschlich (2016), que é o estado-da-arte em segmentação de impressões digitais. Dessa forma, usamos essa metodologia de comparação para avaliar o algoritmo de segmentação proposto neste trabalho em relação a esses métodos. Todavia, a métrica desenvolvida por Thai et al. não é muito utilizada 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 métodos 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 4.12 é possível ver a diferença entre imagens com regiões pequenas e grandes de impressão digital, quando comparadas com a imagem inteira. A Figura 4.12(a) é a imagem de impressão digital 53_2.bmp da base de dados FVC2004 DB1, a Figura 4.12(b) é a imagem segmentada manualmente por Thai et al. (2016), a Figura 4.12(c) é a imagem segmentada automaticamente pelo método de segmentação desenvolvido neste trabalho e

a Figura 4.12(d) é a imagem de saída resultante do método de comparação de Thai et al., usando as Figuras 4.12(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 4.12(e) foi realizado um recorte buscando reduzir a área de *background* e provar a hipótese levantada. A imagem resultante (Figura 4.12(h)) obteve um erro de 2.68%, que é relativamente maior comparado ao erro da Figura 4.12(d), mesmo sendo as mesmas imagens, excetuando-se a operação de recorte. Assim, optou-se por também utilizar o método de Jaccard para avaliar o método proposto, uma vez que o mesmo é mais aceito e confiável e mais insensível ao recorte.

Figura 4.12: 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 et al. (2016). A região branca é a região de interseção. Fonte: próprio autor.



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 utilizado 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 and Gottschlich, 2016). A seleção de parâmetros para os métodos FDB (Thai et al., 2016), GFB (Shen et al., 2001a) ,

HCR (Wu et al., 2007) , MVC (Bazen and Gerez, 2001) e STFT (Chikkerur et al., 2007) é discutida em Thai et al. (2016).

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

Tabela 4.2: Parâmetros utilizados no método proposto.

Parâmetros	Descrição
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_σ	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 método: H_e , H_q e l . Eles foram utilizados usando o banco de treinamento e aplicados sobre o banco de testes de cada base de dados. Para cada banco de treinamento, os parâmetros foram variados afim de encontrar a melhor combinação de valores. A partir daí, os valores são utilizados nos bancos de teste e são mostrados na Tabela 4.3. Os parâmetros restantes foram definidos manualmente para todas as bases de dados depois de testes empíricos. 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.

	FVC	BD	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	

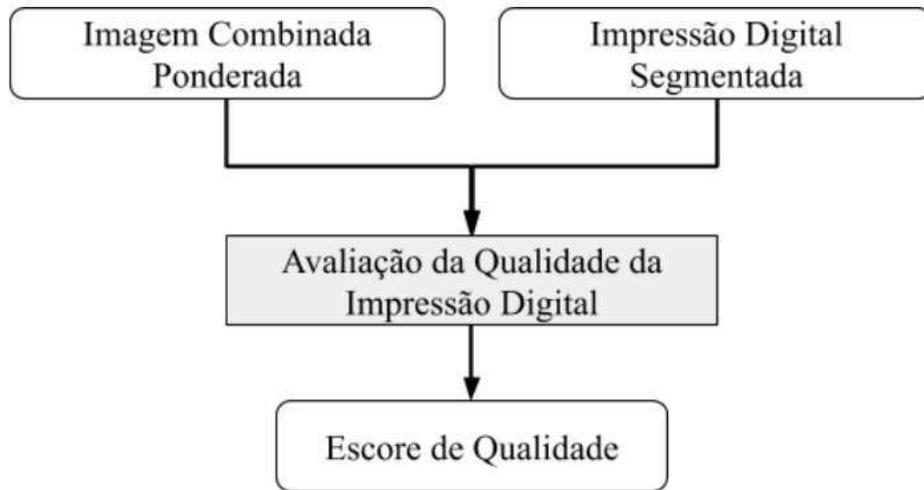
4.3.4 Avaliação da Qualidade Global

Após a criação da imagem combinada ponderada e a definição da região de interesse na imagem de impressão digital, dar-se início ao processo de avaliação da qualidade da impressão digital. Esse valor auxilia na avaliação dos atributos extraídos da imagem de impressão digital, bem como no processo de casamento.

Abordagem Proposta

O método proposto realiza a avaliação da qualidade a partir da intensidade da resposta da convoluções das máscaras de Gabor na imagem de impressão digital. O algoritmo tem como entrada a imagem combinada ponderada e a imagem da região de interesse. A saída do algoritmo é o escore de qualidade da impressão digital, como mostrado na Figura 4.13.

Figura 4.13: Processo de avaliação da qualidade de uma impressão digital. Fonte: próprio autor.

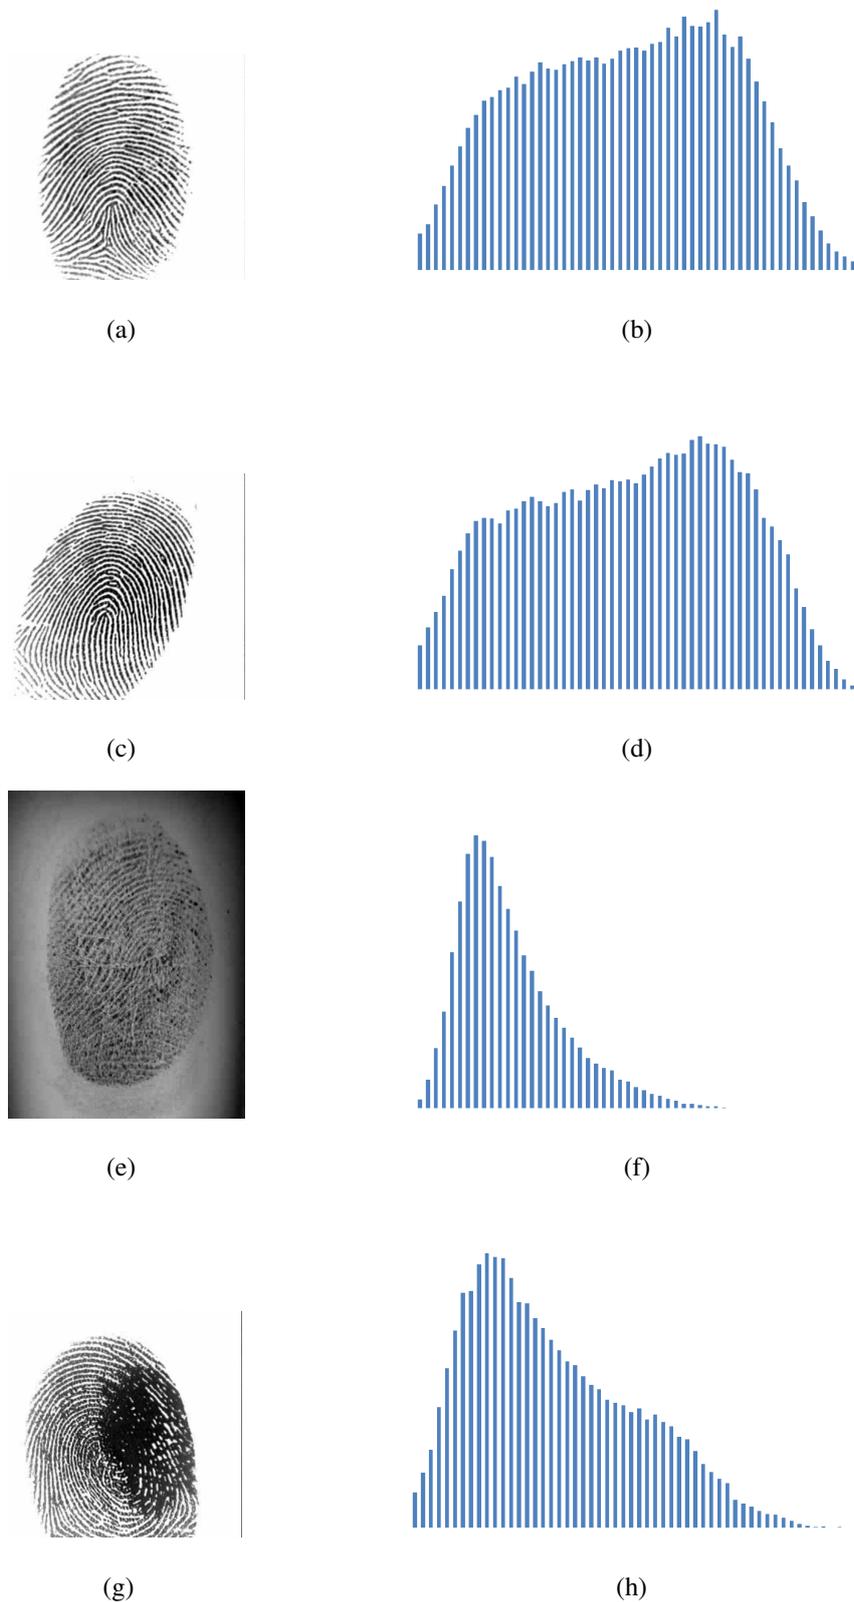


Para a avaliação da qualidade, apenas a intensidade da imagem combinada é levada em consideração, não o fato de o pixel ser uma resposta para uma crista ou um vale. Portanto, o valor absoluto é analisado (Equação 4.6).

$$P_{abs} = |P| \quad (4.6)$$

Então, o histograma de P_{abs} é calculado (Figura 4.14). Quando uma imagem de impressão digital tem uma boa qualidade (Figuras 4.14(a) e 4.14(c)), as linhas das cristas e dos vales estão bem definidas, conseqüentemente, os valores de P_{abs} são mais altos. Dessa forma, o histograma é mais denso no lado direito (Figuras 4.14(b) e 4.14(d)). Caso contrário, se a imagem da impressão digital possuir baixa qualidade (Figuras 4.14(e) e 4.14(g)), o histograma será mais denso no lado esquerdo, onde os valores são mais baixos (Figuras 4.14(f) e 4.14(h)).

Figura 4.14: Ilustração da análise de P_{abs} . A coluna da esquerda são exemplos de impressão digital e a coluna da direita (imagens (b), (d), (f) e (h)) é o histograma de P_{abs} calculado a partir da respectiva imagem de impressão digital. As imagens (a) e (c) são impressões digitais de melhor qualidade do que (e) e (g). Fonte: próprio autor.



Pode-se notar que em imagens de qualidade baixa a distribuição do histograma de P_{abs} fica mais concentrado em regiões mais a esquerda (próximos a 0). Já em imagens onde a impressão digital está mais nítida, em relação as suas minúcias, a distribuição do histograma de P_{abs} fica mais homogênea, concentrada mais à direita.

Para identificar esse comportamento, o *skewness* é calculado (conforme a Equação 4.7). *Skewness* é uma medida da assimetria da distribuição de probabilidade dos valores sobre sua média. Quando o valor da medida é negativo, a cauda do lado esquerdo é mais longa que a da direita e quando o valor da medida de assimetria é positivo a cauda do lado direito é mais longa que a da esquerda.

$$S = \frac{\mu_3}{\sigma^3} \quad (4.7)$$

onde μ_3 é o terceiro momento central e σ é o desvio padrão.

A partir do valor negativo do *skewness* é calculado o escore de qualidade da impressão digital (FQS). O valor de S é limitado entre uma faixa de valores e normalizado de 0 (qualidade mínima) a 100 (qualidade máxima). A Equação 4.8 representa o cálculo do escore:

$$FQS = \begin{cases} 0 & \text{se } -S < min \\ -\frac{100(S+min)}{max-min} & \text{se } min \leq -S \leq max \\ 100 & \text{se } -S > max \end{cases} \quad (4.8)$$

onde min e max são os parâmetros usados para limitar o valor de S .

Os limitadores são utilizados para delimitar o menor e o maior valor de qualidade. Se o valor de $-S$ estiver fora da abrangência do min e max , o escore será 0 ou 100, respectivamente. Se os valores dos parâmetros forem muito próximos, teremos muitos escores em 0 ou 100. Caso contrário, uma grande diferença entre min e max pode causar uma grande concentração dos escores de qualidade.

Nos experimentos foram utilizados -2 e 0 para min e max , respectivamente. Esses valores foram obtidos a partir das respostas do *skewness* nos bancos de validação. Foi observado que a maioria das respostas estavam concentradas entre os valores definidos acima.

Validação do Método de Qualidade Global

As bases de dados de imagens de impressões digitais utilizadas para avaliar o método de segmentação proposto foram as bases de dados do FVC2000DB3, FVC2004DB2, FVC2004DB3 e FVC2006DB3 (Cappelli et al., 2007). Essas bases de dados foram selecionadas por serem comumente utilizadas na literatura. Além disso, os problemas de qualidade apresentados nesses conjuntos de dados são conhecidos por afetar o desempenho do sistema automático de identificação de impressões digitais (Phromsuthirak and Areekul, 2013). As três primeiras bases são compostas por 800 imagens (100 dedos com 8 amostras por dedo). Já a base de dados do FVC2006DB3 é composta por 140 dedos com 12 amostras por dedo, totalizando 1680 imagens.

Para validar a abordagem de avaliação da qualidade de impressão digital apresentada, duas análises diferentes foram realizadas: a correlação entre o FQS e o EER resultante. Em seguida, foi medido o efeito de remover as imagens de pior qualidade em relação ao EER.

Este método foi comparado a outros dois métodos bem conhecidos de Fingerprint Quality Assessment (FQA): Qualidade de Imagem de Impressão Digital NIST (NFIQ) Tabassi et al. (2004) e o FQA comercial do VeriFinger SDK, desenvolvido pela Neurotechnology. Dois SDKs comerciais diferentes foram usados para extração e casamento dos *templates*: o SDK do BioPass da Vsoft Tecnologia e o VeriFinger da Neurotechnology.

4.3.5 Realce da Impressão Digital (*Enhancement*)

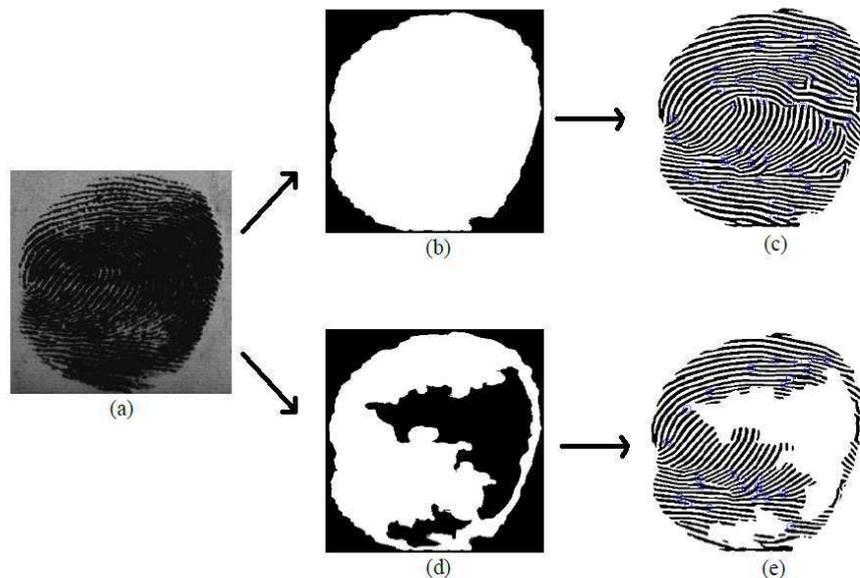
O método de realce utilizado pelo método proposto é baseado no trabalho desenvolvido por Turrone et al. (2012), que utiliza filtragem iterativa por filtros de Gabor. O método de realce implementado por Turrone et al. (2012) mostrou-se bastante eficiente, contudo, os mesmos citaram alguns problemas além 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 para retirar as regiões com baixa qualidade. Com isso, o método de realce foi aplicado apenas nos pixels provenientes da imagem de entrada que faziam parte da ROI (região branca na Figura 4.15(b)). A Figura 4.15 mostra a diferença que a imagem segmentada representa para o resultado final da extração de minúcias. Na Figura 4.15(b) foi utilizada uma ROI completa, apenas diferenciando *background* e *foreground*, resultando em uma imagem final (Figura 4.15(c)) com várias minúcias falsas (círculos azuis) e, conseqüentemente aumentando as taxas de erro nos sistemas de identificação. Na Figura 4.15(d) o método de segmentação exclui as regiões de baixa qualidade, obtendo uma menor quantidade de falsas minúcias.

Figura 4.15: Realce de impressões digitais por meio das diferentes abordagens de segmentação. Fonte: próprio autor.



Além disso, foi realizada uma outra modificação referente ao valor percentual γ 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 uma grande quantidade de iterações

para finalizar o processo, caso o valor de γ seja muito pequeno, e um realce muito agressivo, provavelmente com erros, caso o valor de γ 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 γ com um valor fixo e é incrementado a cada iteração, conforme descrito na equação 4.9.

$$\gamma_{It} = \gamma_{It-1} + (\beta \cdot It) \quad (4.9)$$

em que β 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 γ foi definido como 0.15, significando que os 15% melhores pixels de cada extremidade serão realçados na primeira iteração. Na segunda iteração ($It = 1$) o valor de γ será de 0.20 e assim sucessivamente até chegar na condição de parada, definida pelo valor de γ igual a 0.40.

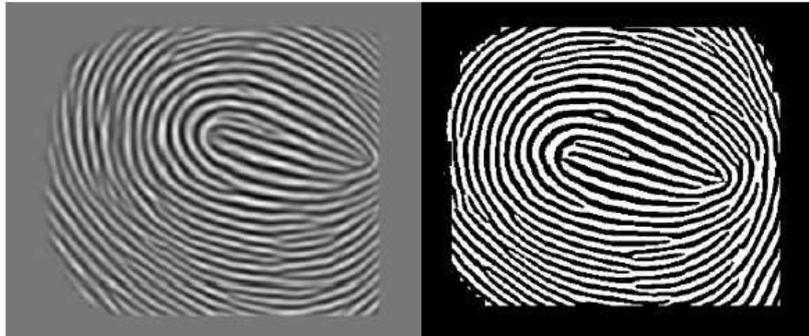
Dessa forma, nas iterações posteriores o método de realce fica mais agressivo já que as imagens resultantes dessas novas iterações possuem uma melhor qualidade, resultando ao fim em uma menor quantidade de iterações necessárias para realçar a imagem por completo.

4.4 Afinamento, Localização e Filtragem de Minúcias

Após a etapa de realce, o método 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, dado 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 a seguir.

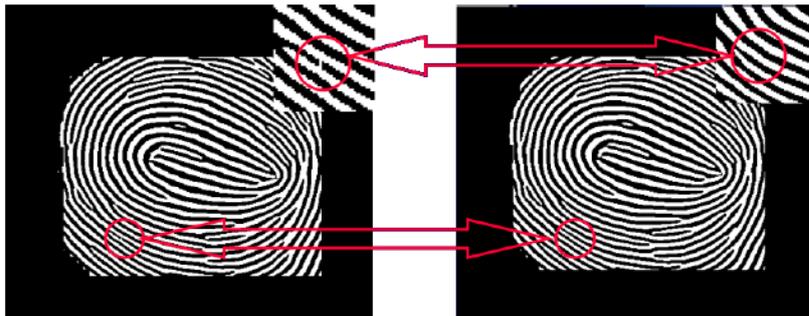
- Binarização local – A imagem resultante da filtragem por Gabor é binarizada utilizando um limiar. Caso o pixel esteja abaixo do limiar ele é convertido para preto, caso contrário, o pixel será branco (Figura 4.16).

Figura 4.16: Binarização local. Fonte: próprio autor.



- Filtro da mediana sobre imagem binarizada – É aplicado um filtro da mediana para retirar o ruído proveniente das etapas anteriores (Figura 4.17). A máscara utilizada é de 3x3 pixels.

Figura 4.17: Aplicação do filtro da mediana local. Fonte: próprio autor.



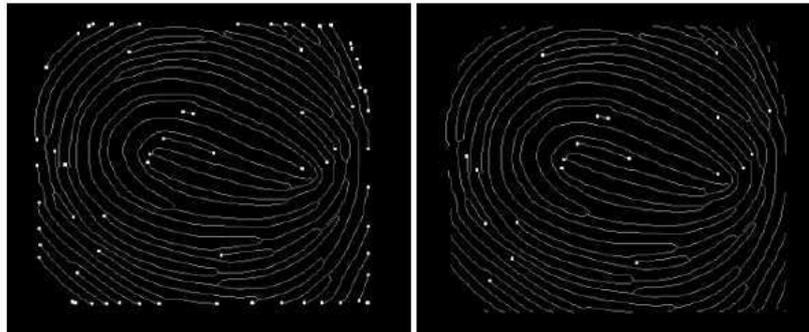
- Criação do esqueleto e extração das características – É realizado um afinamento sobre a imagem final, transformando as cristas em linhas de espessura de apenas 1 pixel para facilitar a extração das minúcias (Figura 4.18).

Figura 4.18: Afinamento das cristas. Fonte: próprio autor.



- 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 4.19).

Figura 4.19: Remoção de falsas minúcias. Fonte: próprio autor.



4.5 Metodologia de Avaliação

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 (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 o FVC.

As imagens utilizadas para medir a eficácia do método são provenientes de 5 bancos utilizados em edições anteriores do FVC. Foram utilizados os bancos DB3 da edição 2000, DB1 da edição 2002, DB1 e DB2 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 do banco DB2 FVC2006 que possui resolução 569 DPI. 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 4880 amostras distribuídas entre os bancos, os 4 primeiros citados anteriormente possuem 800 amostras, sendo 8 amostras por dedo, para 100 dedos.

Além disso é realizada uma análise comparativa entre este trabalho e alguns métodos de extração de características desenvolvidos por diferentes fontes. O primeiro método comparado é o de extração do SourceAFIS, que é um método de código aberto e está disponível

no site do projeto (SourceAFIS,2015), 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 método de extração.

O segundo método é o método de extração da Neurotechnology, empresa líder mundial nas maiores competições de identificação, como o FVC e o MINEX. Não é possível ter acesso ao código, pois a Neurotechnology é uma empresa privada e são disponibilizadas apenas algumas DLLs para executar o método. Além disso, a empresa não possui interesse em disponibilizar artigos científicos por motivos comerciais. Também são utilizados os métodos que foram comparados no trabalho de Turrone et al. (2012), sendo eles os métodos desenvolvidos por Hong et al. (1998), Sutthiwichaiorn et al. (2010) e o próprio método desenvolvido por Turrone et al. (2012). Os experimentos de casamento são conduzidos utilizando o protocolo do FVC (BioLab, 2006).

Os métodos propostos são executados sobre cada banco individualmente e as referências para os templates extraídos são armazenadas em um banco de dados auxiliar (SQLite). Após essa etapa é executado o método de casamento desenvolvido pelo Biolab Cappelli et al. (2010), conhecido como *Minutia cylinder-code*(MCC), para todos os templates previamente extraídos. Ao utilizar um único método de Matching para cada um dos métodos de extração em estudo, há uma garantia de que as variações nos resultados e taxas de erros serão provenientes apenas dos métodos de extração, podendo ser realizada uma comparação justa entre eles.

Após a realização do casamento de minúcias, o score é computado a partir dos atributos obtidos. Com a análise desses dados será possível determinar as taxas de FAR e FRR, e determinar o melhor limiar baseado no EER.

Para cada banco de imagens é realizado 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 comparações 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, são 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, são realizadas $((100*99) / 2) = 4.950$ comparações. Para o banco FVC2006 são realizadas $((140*139) / 2) = 9,730$ comparações. Finalizando, são realizadas para os primeiros bancos, 9.450 comparações em cada um e para o último banco, 18.970 comparações.

Capítulo 5

Resultados e Discussões

Neste capítulo, são apresentados os principais resultados obtidos pelos métodos propostos e desenvolvidos nesta pesquisa, realizando comparações com os principais métodos, considerados o estado da arte em suas devidas áreas. Além disso, são apresentadas as discussões sobre os resultados.

5.1 Resultados de Segmentação

O método de avaliação proposto por Thai et al. (2016) compara os cinco métodos de segmentação mais citados na literatura à época daquela publicação. Assim, para avaliar o método proposto, o método de segmentação desenvolvido neste trabalho foi comparado com esses métodos considerados o estado-da-arte na segmentação de impressões digitais. A Tabela 5.1 mostra todos os resultados obtidos pelos métodos utilizando a métrica de comparação de Thai et al. (2016). Os métodos comparados são: GFB Shen et al. (2001a), HCR Wu et al. (2007), MVC Bazen and Gerez (2001), STFT Chikkerur et al. (2007), FDB Thai et al. (2016), G3PD Thai and Gottschlich (2016) e o método desenvolvido neste trabalho, chamado de Biopass Segmentation (BPS).

Tabela 5.1: Comparação dos métodos utilizando o método de comparação proposto por Thai et al. Os valores representam a taxa de erro da imagem segmentada em relação ao gabarito.

FVC	DB	GFB	HCR	MVC	STFT	FDB	G3PD	BPS
2000	1	13.26	11.15	10.01	16.70	5.51	5.69	4.49
	2	10.27	6.25	12.31	8.88	3.55	4.10	4.00
	3	10.63	7.80	7.45	6.44	2.86	2.68	2.33
	4	5.17	3.23	9.74	7.19	2.31	2.06	2.03
2002	1	5.07	3.71	4.59	5.49	2.39	1.72	1.59
	2	7.76	5.72	4.32	6.27	2.91	2.83	2.67
	3	9.60	4.71	5.29	5.13	3.35	3.27	3.16
	4	7.67	6.85	6.12	7.70	4.49	3.63	3.61
2004	1	5.00	2.26	2.22	2.65	1.40	0.88	1.12
	2	11.18	7.54	8.06	9.89	4.90	4.62	4.61
	3	8.37	4.96	3.42	9.35	3.14	2.77	2.60
	4	5.96	5.15	4.58	5.18	2.79	2.53	2.49
Avg.		8.33	5.78	6.51	7.57	3.30	3.06	2.89

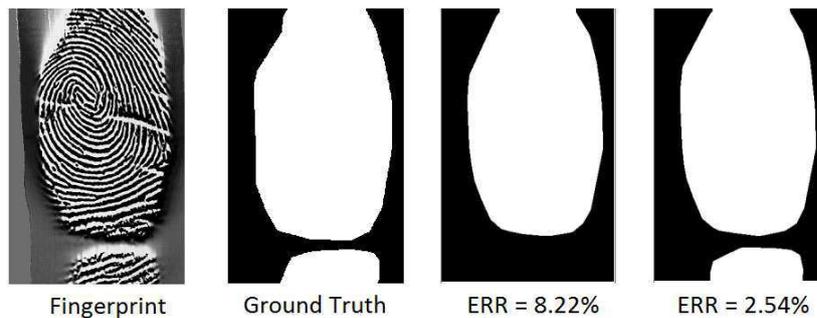
Como mostrado na Tabela 5.1, o método desenvolvido, denominado BPS (BioPass Segmentation) obteve melhores resultados em 10 das 12 bases de dados testadas, em comparação com os outros sete métodos listados.

Comparando especificamente com o método do estado-da-arte (Thai and 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 método 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 método 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 método proposto 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%). Fonte: próprio autor.



Nesse 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 (Jaccard e Thai et al. (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., 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.

Tabela 5.2: Taxas de erros obtidas pela diferença entre as imagens segmentadas pelo método de segmentação proposto e as imagens segmentadas manualmente criadas por Thai et al., utilizando as duas técnicas de comparação citadas (Jaccard e Thai et al.).

	DB	BPS (Jaccard)	BPS(Métrica de Thai et al.)
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 método de segmentação desenvolvido também é outro foco de pesquisa, se tornando mais um aspecto a ser melhorado. O tempo médio para a extração da ROI 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.

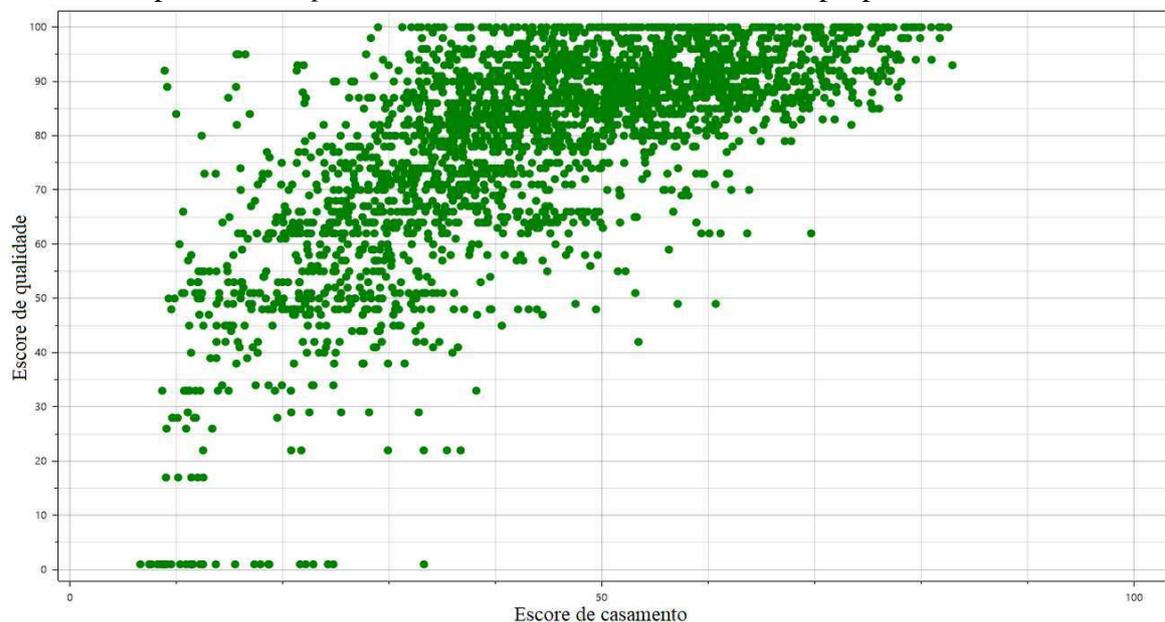
5.2 Resultados da Avaliação da Qualidade da Impressão Digital

5.2.1 Análise da Correlação

Um casamento genuíno (entre amostras do mesmo dedo) tende a produzir escore maior do que entre um casamento impostor (entre amostras de dedos diferentes). No entanto, a correspondência genuína pode resultar em uma pontuação baixa devido a alguns fatores, como a falta regiões de intersecção, falhas de aquisição ou imagens de baixa qualidade. Para aumentar a precisão do método, pode-se diminuir a quantidade de erros de casamentos genuínos (falsa rejeição).

Inicialmente, foi avaliado o impacto da qualidade dos *templates* sobre o escore de casamento genuíno. A Figura 5.2 indica que na maioria dos casos em que o escore do casamento é baixo, o escore de qualidade do *template* também é baixo.

Figura 5.2: Relação entre o escore de casamentos genuínos e o menor escore de qualidade dos seus respectivos *templates* no banco FVC2000DB3. Fonte: próprio autor.



A partir dessa avaliação foi realizado o coeficiente de correlação de *Pearson* para medir o grau da relação entre o escore do casamento e a qualidade dos *templates*. A nível de comparação, foram utilizado 2 FQAs (NFIQ e VeriFinger), além do desenvolvido nesta tese

(BPFQ). Para a extração e casamento dos *templates*, foram utilizados 2 AFIS (BioPass e VeriFinger). A Tabela 5.3 apresenta os coeficientes de correlação de *Pearson*.

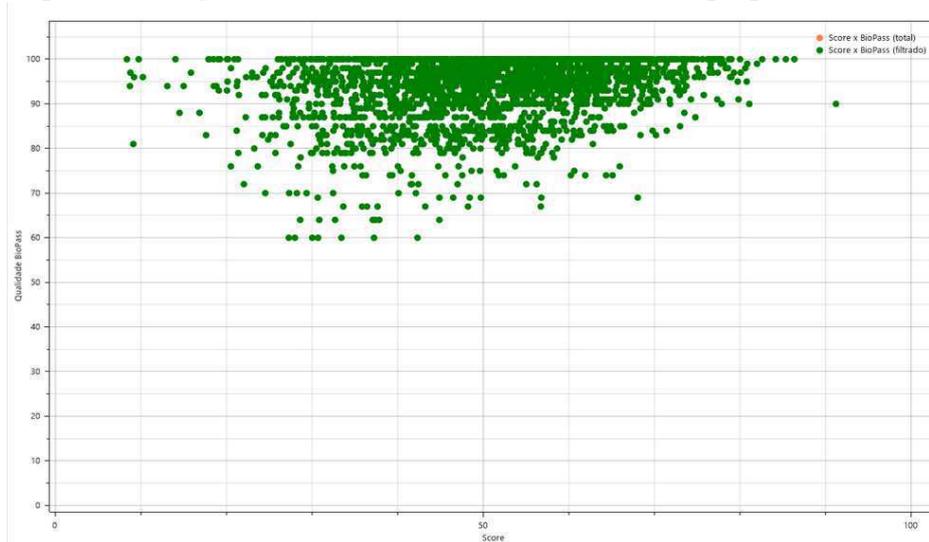
Tabela 5.3: Coeficiente de correlação de *Pearson* entre o escore de casamento e a qualidade dos *templates* para os algoritmos NFIQ, VeriFinger e o desenvolvido nessa tese (BPFQ).

AFIS	FQA	00DB3	04DB2	04DB3	06DB3
BioPass	VeriFinger	0.59	0.48	0.57	0.55
	NFIQ	0.52	0.49	0.45	0.23
	BPFQ	0.67	0.59	0.63	0.55
VeriFinger	Verifinger	0.62	0.49	0.60	0.52
	NFIQ	0.58	0.54	0.46	0.25
	BPFQ	0.63	0.56	0.57	0.51

Os resultados apresentados mostram que o método desenvolvido alcançou correlação moderada ou forte para todos os conjuntos de testes, independentemente do AFIS. Além disso, os coeficientes de correlação com o algoritmo de qualidade desenvolvido é maior na maiorias dos casos. A média do coeficiente de correlação é 5,45% e 31,81% VeriFinger e NFIQ, respectivamente. Isso implica que o escore de qualidade obtido nesse trabalho possui uma melhor relação com o escore de casamento que com os algoritmos VeriFinger e NFIQ.

Nos 4 bancos avaliados, as imagens não aparentam, em sua grande maioria, uma boa qualidade. Já no banco FVC2002DB01, a maioria das imagens apresentam as cristas e os vales bem definidos. Nesse banco a correlação entre a qualidade medida pelo algoritmo desenvolvido e o AFIS BioPass foi 0.26 (considerada uma correlação fraca). A relação entre escore de casamento e qualidade das imagens pode ser vista na Figura 5.3.

Figura 5.3: Relação entre o escore de casamentos genuínos e o menor escore de qualidade dos seus respectivos *templates* no banco FVC2002DB1. Fonte: próprio autor.



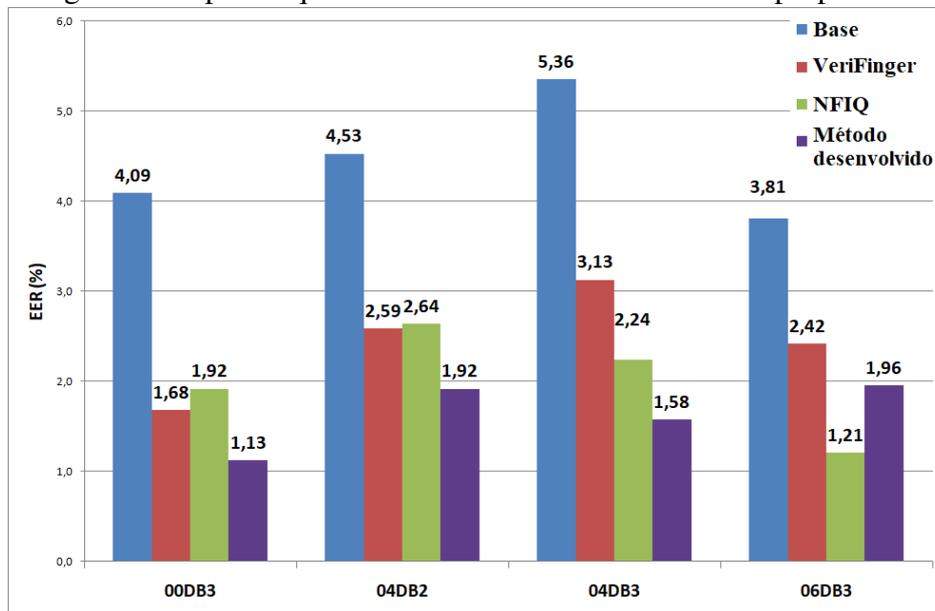
Com isso, esse banco não será avaliado nas próximas seções, já que os limiares de qualidade não afeta o banco, pois as imagens possuem as minúcias bem definidas.

5.2.2 Impacto da Qualidade na Taxa de Erro

Após analisar a relação entre o escore do casamento dos *templates* e o escore de qualidade, foi avaliada a influência das impressões digitais com escore de qualidade baixo na falsa aceitação ou falsa rejeição. Para isso, foram realizados testes retirando imagens de impressão digital dos bancos de dados.

O primeiro passo foi analisar a EER, obtida pelo AFIS BioPass, removendo 10% das imagens de pior qualidade do banco. A Figura 5.4 compara os resultados de cada método para todos os quatro conjuntos de dados do FVC.

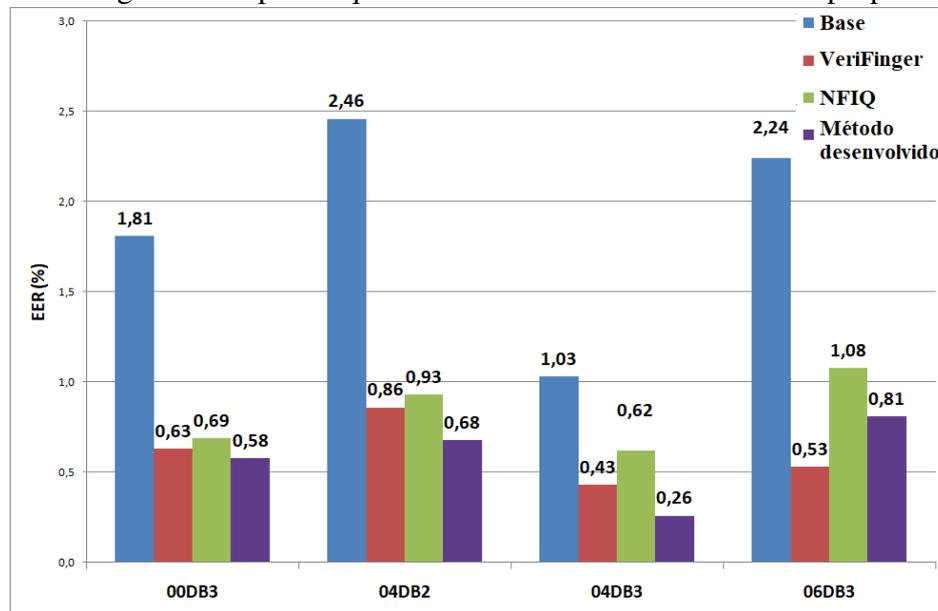
Figura 5.4: Taxa de erro igual obtida pelo AFIS BioPass quando removidos 10% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.



A EER foi reduzida em todos os bancos de dados, com ganhos de 48,55% (FVC2006DB3) até 72,37% (FVC2000DB3). Em média, a retirada das impressões digitais, utilizando o algoritmo de qualidade desenvolvido, diminuiu a EER em 60,57%, enquanto o NFIQ e o Verifinger diminuíram em 41,61% e 52,91%, respectivamente.

Em seguida, foi realizado o mesmo teste utilizando o AFIS VeriFinger SDK. O algoritmo apresentado obteve melhor desempenho em 3 dos 4 bancos de dados. Como pode ser visto na Figura 5.5, a menor redução de EER foi de 63,83% (FVC2006DB3) e a maior de 74,75% (FVC2004DB3).

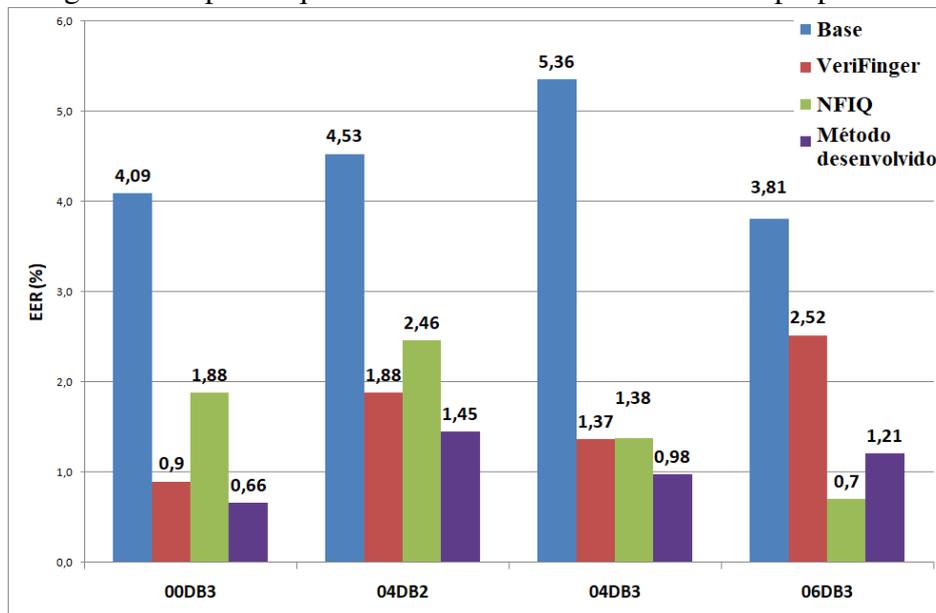
Figura 5.5: Taxa de erro igual obtida pelo AFIS da VeriFinger quando removidos 10% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.



Em média, a EER foi melhorada em 69,72% através método desenvolvido e 53,91% e 66,20% usando NFIQ e VeriFinger, respectivamente. Finalmente, pode ser visto que o método de avaliação da qualidade da impressão digital apresentado consegue taxas de erro menores que o VeriFinger, mesmo quando o VeriFinger SDK é usado para a extração e o casamento dos *templates*.

O teste seguinte foi analisar a EER, obtida pelo AFIS BioPass, removendo 20% das imagens de pior qualidade do banco. A Figura 5.6 compara os resultados de cada método para todos os quatro conjuntos de dados do FVC.

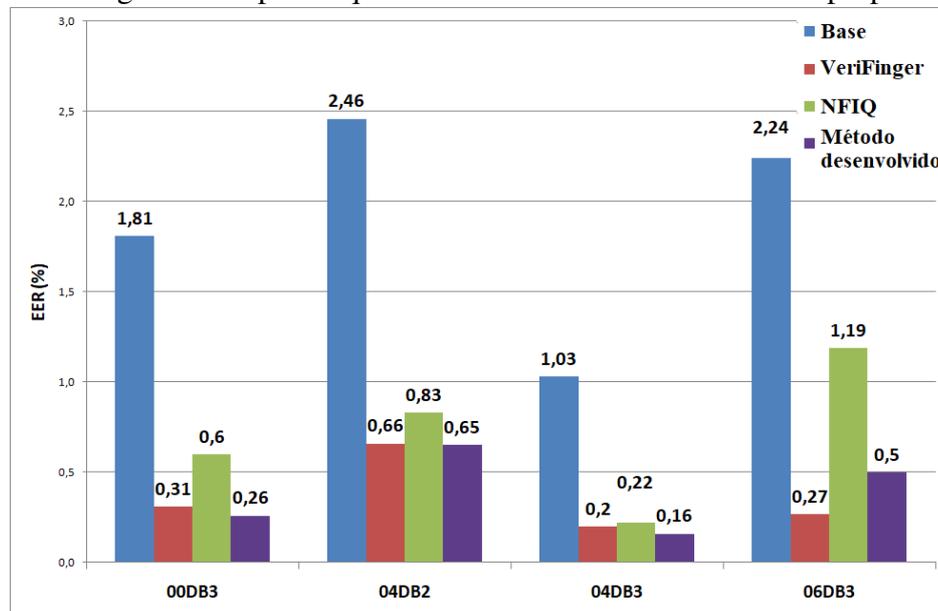
Figura 5.6: Taxa de erro igual obtida pelo AFIS BioPass quando removidos 20% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.



A EER foi reduzida em todos os bancos de dados, com ganho mínimo de 67,99% (FVC2006DB3) e máximo de 83,86% (FVC2000DB3). Em média, a retirada das impressões digitais, utilizando o algoritmo de qualidade desenvolvido, diminuiu a EER em 75,82%, enquanto o NFIQ e o Verifinger diminuiram em 63,91% e 62,50%, respectivamente.

Em seguida, foi realizado o mesmo teste utilizando o AFIS VeriFinger SDK (Figura 5.5). O algoritmo apresentado obteve melhor desempenho em 3 dos 4 bancos de dados, mesmo quando o VeriFinger SDK é usado para a extração e o casamento dos *templates*.

Figura 5.7: Taxa de erro igual obtida pelo AFIS da VeriFinger quando removidos 20% dos das impressões digitais com piores qualidades nas bases do FVC. Fonte: próprio autor.



A menor redução de EER foi de 77,67% (FVC2006DB3) e a maior de 85,63% (FVC2000DB3). Em média, a EER foi melhorada em 80,33% através método desenvolvido e 64,65% e 81,14% usando NFIQ e VeriFinger, respectivamente.

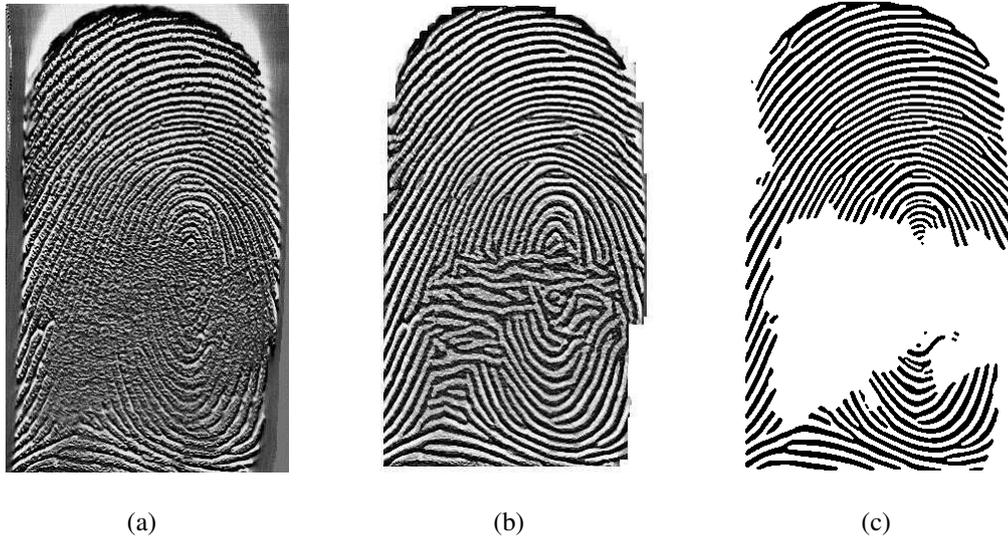
5.3 Resultados na Melhoria do Realce

Esta seção está dividida em três etapas: Inicialmente são avaliadas as melhorias aplicadas no processo de realce. Em seguida, são apresentadas as comparações com outros trabalhos através da EER. Por fim, o método desenvolvido é aplicado com o método de casamento do BioPass e avaliado nas bases do FVC.

5.3.1 Retirada de Regiões Irrecuperáveis na Impressão Digital

O primeiro teste foi avaliar o impacto da retirada de regiões irrecuperáveis da ROI no processo de realce da imagem da impressão digital. A Figura 5.8 mostra a comparação entre o método de realce proposto por Turrone et al. (2012) e as melhorias realizadas nessa tese.

Figura 5.8: Realce de imagens de impressões digitais com regiões irrecuperáveis. (a) Imagem original presente na base de dados do FVC2004; (b) Realce utilizando o método iterativo contextual Turrone et al. (2012); (c) Realce utilizando o método desenvolvido. Fonte: próprio autor.



Na Figura 5.8 (b) o realce é aplicado em toda a região pertencente à impressão digital. Porém, em regiões irrecuperáveis da imagem de impressão digital, as cristas são reconstruídas erroneamente e geram falsas minúcias. Retirando as regiões irrecuperáveis (Figura 5.8 (c)), o realce é aplicado sem a criação de falsas minúcias, podendo diminuir os erros durante o processo de casamento entre os *templates*.

Em seguida, foi realizada uma análise quantitativa do aprimoramento do realce da impressão digital. Os testes foram realizados usando o algoritmo de casamento de impressão digital *BioPass Match* proposto por Araújo (2015). A Tabela 5.4 apresenta a taxa de erro igual (EER) do algoritmo sobre as bases do FVC.

Tabela 5.4: Avaliação dos algoritmos de realce a partir da EER obtida pelo algoritmo de casamento *BioPass Match*.

	Sem melhorias	Com melhorias
FVC2000DB3	4,14%	3,28%
FVC2002DB1	0,95%	0,85%
FVC2004DB1	5,06%	4,03%
FVC2004DB2	4,77%	3,42%
FVC2004DB3	5,36%	3,62%
FVC2006DB2	0,26%	0,21%
Média	3,42%	2,56%

As melhorias aplicadas no processo de realce obteve redução da EER em todos os bancos testados. A média da EER caiu de 3,42% para 2,56%, equivalente a uma redução de 25%.

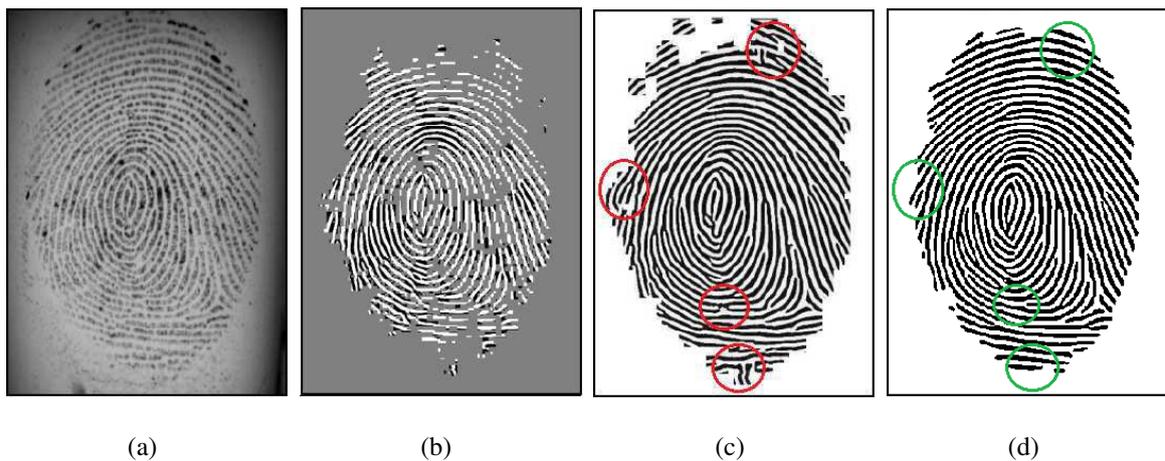
O tempo de processamento do algoritmo apresentado por Turrone et al. (2012) varia em torno de 10 segundos por imagem, o que é um grande empecilho para sua utilização em ambientes reais. Já o tempo médio do método desenvolvido nesta tese foi de 1,9 segundos por imagem, o que representa uma melhoria de 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.

5.3.2 Comparação com outros Trabalhos

O algoritmo de realce desenvolvido foi comparado com outros três algoritmos: o método de referência Gabor (Hong et al., 1998), o método iterativo contextual (Turrone et al., 2012) e um aprimoramento de impressão digital presente em SourceAFIS (Važan, 2009). Todos os experimentos correspondentes foram conduzidos seguindo o protocolo FVC (BioLab, 2006). Outros métodos encontrados na literatura não foram utilizados nos experimentos devido às suas limitações, como o algoritmo de comparação não mencionado, o uso de diferentes algoritmos de comparação e abordagens incompatíveis para medir a eficiência dos algoritmos.

A Figura 5.9 mostra uma análise comparativa visual dos algoritmos aplicados em uma imagem de impressão digital.

Figura 5.9: Realce de impressões digitais com vários algoritmos. (a) Imagem original presente no banco de dados do FVC2006DB2, (b) Aprimorado usando filtros de Gabor (Hong et al., 1998), (c) Aprimorado usando o método iterativo contextual (Turrone et al., 2012), (d) Aprimorado usando o método proposto. Círculos verdes indicam as regiões que foram corretamente melhoradas usando o método proposto, enquanto que os círculos vermelhos são as mesmas regiões, mas aumentadas incorretamente por Turrone et al. (2012). Fonte: próprio autor.



Na Figura 5.9, pode-se notar que a reconstrução das regiões de impressão digital pelo nosso algoritmo foi realizada preservando regiões bem definidas, reconstruindo regiões recuperáveis e removendo regiões irrecuperáveis. Além disso, é importante observar que outros algoritmos removeram algumas regiões recuperáveis nas bordas da imagem de impressão digital, deixando de extrair possíveis minúcias genuínas (Figura 5.9 (b)). As principais diferenças entre o aprimoramento proposto por Turrone et al. (2012) (Figura 5.9 (c)) e o método de realce desenvolvido (Figura 5.9 (d)) são indicados por círculos vermelhos e verdes, respectivamente. O algoritmo Turrone et al. (2012) cometeu alguns erros, criando minúcias espúrias, enquanto círculos verdes são as mesmas regiões com nosso método de realce.

Em seguida, foi realizada uma análise quantitativa do realce da impressão digital. Os testes foram realizados usando um algoritmo de casamento de impressão digital comum para avaliar os algoritmos de realce de impressões digitais. A fim de comparar as melhorias propostas com relação ao trabalho proposto por Turrone et al. (2012), foi usado o *Minutia Cylinder-Code* (MCC) apresentado por Cappelli et al. (2010). A Tabela 5.5 apresenta a taxa de erro igual (EER) dos algoritmos sobre as bases do FVC.

Tabela 5.5: Avaliação dos algoritmos de realce a partir da EER obtida pelo algoritmo de casamento MCC.

	Gabor	Turroni et al. (2012)	Source AFIS	Método desenvolvido
FVC2000DB3	-	-	6.74%	2.40%
FVC2002DB1	-	-	1.22%	0.71%
FVC2004DB1	-	-	6.24%	4.22%
FVC2004DB2	6.569%	5.678%	7.40%	4.85%
FVC2004DB3	3.640%	3.175%	3.90%	2.45%
FVC2006DB2	2.325%	0.659%	0.64%	0.38%
Média	4,18%	3.17%	4.35%	2.50%

Os resultados mostram que os aprimoramentos de realce realizados obtiveram melhores taxas de erro do que os demais algoritmos. Em relação a Turroni et al. (2012), os ganhos foram 14,6%, 22,7% e 42,4% em FVC2004DB2, FVC2004DB3 e FVC2006DB2, respectivamente, tendo assim uma melhora de 21% em média. Observa-se que o método proposto também supera as taxas de algoritmo de melhoramento de impressões digitais disponíveis no SourceAFIS (Važan, 2009).

5.3.3 Avaliação do AFIS BioPass

O método de extração desenvolvido neste trabalho foi avaliado por meio da competição internacional FVC-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 método de casamento de impressões digitais desenvolvido por Araújo (2015), criando um AFIS completo com esses dois módulos.

A Tabela 5.6 mostra o desempenho do método proposto, fonte de cor esverdeada, em relação aos demais competidores de todas as versões do FVC. Observa-se que o método proposto alcançaria a primeira colocação no FVC 2000, que teve um total de 11 participantes; oitava colocação no FVC 2002 que teve um total de 31 participantes; sexta colocação em ambas modalidades do FVC 2004-1, onde 41 participaram da modalidade do banco DB1 e 42 participaram da modalidade do banco DB2; e na décima colocação no FVC 2006 que teve

um total de 42 participantes classificados.

Tabela 5.6: Desempenho do método proposto, de cor verde, em relação aos demais candidatos em todas as versões do FVC.

Pos/EER	FVC-OnGoing	DB06	DB04-2	DB04-1	DB02	DB00
1	0,02%	0,02%	1,58%	1,97%	0,10%	3,28%
2	0,02%	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%	3,42%	4,03%	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%	0,85%	16,32%
9	0,29%	0,19%	3,62%	4,37%	0,98%	17,73%
10	0,41%	0,21%	3,75%	5,54%	1,17%	22,63%
11	0,58%	0,24%	4,01%	5,64%	1,46%	23,18%
12	0,61%	0,25%	4,39%	6,13%	1,63%	47,43%
13	0,62%	0,27%	4,67%	6,49%	1,85%	-
14	0,71%	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 método está na décima primeira posição do projeto FVC-OnGoing com taxa de erro de 0,58%. Nesta competição, que está em vigor desde a última versão do projeto BioPass, o banco de dados no qual o método é executado não é conhecido e o método proposto é o único método classificado que é de origem brasileira. É preciso mencionar que dos 10 métodos que estão mais bem colocados, 9 pertencem a empresas privadas e, em geral, não possuem interesse em publicar seus resultados em artigos científicos e apenas um foi

desenvolvido por um grupo de pesquisa acadêmica.

Capítulo 6

Considerações Finais

6.1 Conclusão

Este trabalho apresentou novos métodos para extração de atributos a partir de uma imagem de impressão digital, etapa importante na identificação de indivíduos utilizando este traço biométrico. Foi desenvolvido um novo método de segmentação da imagem de impressão digital e avaliação da qualidade global. Além disso, foi desenvolvido método de realce na imagem de impressão digital, com base em métodos do estado-da-arte, mas com correções de falhas e realização de otimização. A validação destes métodos é realizada de duas maneiras: analisando dos métodos separadamente e calculando o EER nos bancos de impressões digitais disponibilizados pelas versões anteriores do projeto FVC.

Para os experimentos foram utilizadas 4880 imagens de impressões digitais que tiveram seus atributos extraídos e foi utilizado o método de casamento de Araújo (2015) em toda a base. Essas instâncias pertencem a bancos de dados das versões do projeto FVC do ano 2000, 2002, 2004 e 2006.

O método de segmentação da impressão digital, mostrou-se melhor que os encontrados na literatura. O método de segmentação BioPass obteve uma melhoria média de 5.6% comparado com o método do estado da arte. 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. Regiões irrecuperáveis da imagem de impressão digital, mesmo que pertençam à impressão digital, pode acarretar na geração de falsas minúcias e prejudica o processo de casamento. Para cor-

rigir esse problema, foi implementado um método para retirar as regiões irrecuperáveis da segmentação.

O algoritmo de Avaliação da qualidade de Impressão Digital mostrou-se eficiente para reduzir o EER. O método é avaliado em quatro conjuntos de dados de FVC e comparado com outros algoritmos de FQAs (VeriFinger e NFIQ). Nossos resultados mostraram que comparações genuínas de modelos de baixa qualidade geralmente têm baixa pontuação, gerando um resultado falso de rejeição. Quando 10% dos *templates* de pior qualidade foram removidos do conjunto de dados pelo nosso método, a diminuição na EER foi maior em comparação com todos os métodos analisados. A taxa de erro caiu, em média, 60,57%, enquanto que o método NFIQ e Verifinger tiveram uma redução média de 41,61% e 52,91%, respectivamente.

O método de realce da impressão digital foi construído com base em diversas abordagens conhecidas na literatura e por meio de pesquisa científica. Nessa etapa verificou-se que as abordagens utilizadas apresentavam falhas. A aplicação do filtro de Gabor, para destacar as cristas, destacavam regiões irrecuperáveis ou até mesmo fora da impressão digital gerando erros na extração de características. Além disso, foi desenvolvido um método para definir o valor do desvio padrão, utilizado na criação da máscara, de forma dinâmica, que possibilitou melhores resultados no realce das cristas com diferentes frequências.

Ao analisar a possível colocação do método proposto nas versões anteriores do projeto FVC, que realiza o *benchmarking* dos métodos de casamento de impressões digitais submetidos àquela competição, obteve-se a primeira colocação, no FVC 2000; oitava colocação, no FVC 2002; sexta colocação, nos dois bancos testados da versão 2004 do mesmo projeto e a décima colocação na versão 2006 do projeto FVC.

Atualmente o método proposto, combinado ao o método de casamento proposto por Araújo Araújo (2015), está na décima primeira colocação na versão FVC-*OnGoing*, que está em vigor desde a última versão do BioPass, com um desempenho de 0,58% de EER. Atualmente não existem métodos de origem brasileira com resultados apresentados nesta competição além do método proposto.

Em suma, diante do que foi exposto, pode-se considerar que este trabalho atingiu os objetivos esperados. Não obstante, embora a pesquisa científica utilizando este traço biométrico 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 em uma competição com métodos reais.

6.2 Contribuição para a academia

As contribuições apresentadas nesta teste geraram publicações em eventos da área. Dentre eles podemos destacar os seguintes trabalhos:

- *A Novel Fingerprint Quality Assessment Based on Gabor Filters. Conference on Graphics, Patterns and Images, 2018.* (Brasileiro Primo et al., 2018b);
- *Analysis and Improvements of Fingerprint Enhancement from Gabor Iterative Filtering. Conference on Graphics, Patterns and Images, 2018.* (Brasileiro Primo et al., 2018a);
- *A Novel Method for Fingerprint Image Segmentation Based on Adaptive Gabor Filters. Workshop of Computer Vision, 2017.* (Brasileiro Primo et al., 2017a);
- *Analysis of a Genetic Algorithm-based Approach in the Optimization of the SourceA-FIS's Matching Algorithm. International Conference on Scientific Computing, 2015.* (Almeida Junior et al., 2015);
- *A Novel Approach for Fingerprint Singularities Detection. Workshop of Computer Vision, 2017.* (Brasileiro Primo et al., 2017b);

6.3 Trabalhos futuros

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

Uma possível linha de pesquisa será tentar estender o algoritmo de avaliação de qualidade global para regiões específicas da impressão digital. Com isso, poderemos mensurar a qualidade das minúcias e retirar aquelas com valores baixos da geração do *template*. Para otimizar 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. Outra linha de pesquisa será a utilização de redes neurais convolucionais (CNN) como em Li et al. (2018) para melhorar uma imagem de impressão digital. A ideia é permitir que a rede aprenda os melhores filtros possíveis para melhorar uma imagem, mesmo que demore a gerar esses resultados, e antes do treinamento, seja capaz de reproduzir o aprimoramento em outras imagens mais rapidamente.

Referências Bibliográficas

- Almeida Junior, I. A., Brasileiro Primo, J. J., Silva, A. G. A., Parente, R., Marinho, A. S., Batista, L., and Alves Junior, P. (2015). Analysis of a genetic algorithm-based approach in the optimization of the sourceafis's matching algorithm. In *CSC'15 - The 13th International Conference on Scientific Computing*, pages 23–28.
- Araújo, I. (2015). Uma Nova Abordagem de Casamento de Impressões Digitais. Master's thesis, Departamento de Informática, Universidade Federal da Paraíba.
- Ashbaugh, D. R. (1999). *Quantitative–Qualitative Friction Ridge Analysis: An Introduction to Basic and Advanced Ridgeology*. CRC Press.
- Barringer, O. and Tabassi, E. (2011). Fingerprint sample quality metric nfiq 2.0. In *In Proceedings of the International Conference of the Special Interest Group on Biometrics*, pages 167–171.
- Batista, L. V. (2005). Notas de aula da disciplina introdução ao processamento digital de imagens. *João Pessoa*.
- Bazen, A. M. and Gerez, S. H. (2001). Segmentation of fingerprint images. In *Proc. Workshop on Circuits Systems and Signal Processing (ProRISC 2001)*, volume 276280. Citeseer.
- Bennet, D. and Arumuga, P. (2011). Fingerprint matching using hierarchical level features. *International Journal of Computer Science Issues*, 8.
- BioLab (2006). <https://biolab.csr.unibo.it/fvcongoing> . acesso: julho de 2016.
- Bolle, R. M., Connell, J. H., and Ratha, N. K. (2002). Biometric perils and patches. *Pattern Recognition*, 35(12):2727–2738.

- Brasileiro Primo, J. J., Celestino Ramos, R., Cabral de Lima Borges, E. V., Lucena Peixoto Andrezza, I., Vidal Batista, L., and Martins Gomes, H. (2018a). Analysis and improvements of fingerprint enhancement from gabor iterative filtering. In *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, pages 266–273.
- Brasileiro Primo, J. J., Lucena Peixoto Andrezza, I., Cabral de Lima Borges, E. V., Gualberto de Andrade e Silva, A., Vidal Batista, L., and Martins Gomes, H. (2018b). A novel fingerprint quality assessment based on gabor filters. In *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, pages 274–280.
- Brasileiro Primo, J. J., Ramos, R., Andrezza, I., Parente, R., Gomes, H., and Batista, L. (2017a). A novel method for fingerprint image segmentation based on adaptive gabor filters. In *2017 Workshop of Computer Vision (WVC)*, pages 37–42.
- Brasileiro Primo, J. J., Silva, A., Silva, P., Batista, L., and Gomes, H. (2017b). A novel approach for fingerprint singularities detection. In *2017 Workshop of Computer Vision (WVC)*, pages 102–107.
- Cappelli, R., Ferrara, M., Franco, A., and Maltoni, D. (2007). Fingerprint verification competition 2006. *Biometric Technology Today*, 15(7):7–9.
- Cappelli, R., Ferrara, M., and 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., and De Alexandria, A. R. (2014). Techniques of binarization, thinning and feature extraction applied to a fingerprint system. *International Journal of Computer Applications*, 103(10).
- Chen, Y., Dass, S. C., and Jain, A. K. (2005). Fingerprint quality indices for predicting authentication performance. In *International Conference on Audio-and Video-Based Biometric Person Authentication*, pages 160–170. Springer.
- Chikkerur, S., Cartwright, A. N., and 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., and 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.
- Ezeobiejese, J. and Bhanu, B. (2017). *Latent Fingerprint Image Segmentation Using Deep Neural Network*, pages 83–107. Springer International Publishing, Cham.
- Ezeobiejese, J. and Bhanu, B. (2018). Latent fingerprint image quality assessment using deep learning. In *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*.
- Ghosh, A., Pal, N. R., and Pal, S. K. (1991). Image segmentation using a neural network. *Biological Cybernetics*, 66(2):151–158.
- Gonzalez, R. C., Eddins, S., and Woods, R. E. (2004). *Digital image processing using MATLAB*. Number 04; TA1637, G6.
- Harald, C. (1946). *Mathematical methods of statistics*. Princeton University Press Princeton.
- Hong, L., Wan, Y., and 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., and Wang, Y.-C. (2003). An effective algorithm for fingerprint image enhancement based on wavelet transform. *Pattern Recognition*, 36(2):303–312.
- ISO/IEC 19794-2:2005 (2005). Information technology – biometric data interchange formats – part 2: finger minutiae data. <http://www.iso.org/iso/home/store.html>. Online; Acessado em Setembro de 2019.
- Jain, A., Yi Chen, and Demirkus, M. (2006). Pores and ridges: Fingerprint matching using level 3 features. In *18th International Conference on Pattern Recognition (ICPR'06)*, volume 4, pages 477–480.

- Jain, A. K., Ross, A., and 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., and Nandakumar, K. (2011). Introduction. In *Introduction to Biometrics*, pages 1–49. Springer.
- Jirachaweng, S. and Areekul, V. (2007). Fingerprint enhancement based on discrete cosine transform. In *Advances in Biometrics*, pages 96–105. Springer.
- Kaggwa, F., Ngubiri, J., and Tushabe, F. (2014). Evaluation of multiple enrollment for fingerprint recognition. In *Computer & Information Technology (GSCIT), 2014 Global Summit on*, pages 1–6. IEEE.
- Khan, A. I. and Wani, M. A. (2019). Patch-based segmentation of latent fingerprint images using convolutional neural network. *Applied Artificial Intelligence*, 33(1):87–100.
- Kirkpatrick, D. G. and Seidel, R. (1986). The ultimate planar convex hull algorithm? *SIAM journal on computing*, 15(1):287–299.
- Koh, J., Suk, M., and 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 2012.
- Lee, B., Moon, J., and Kim, H. (2005). A novel measure of fingerprint image quality using the fourier spectrum. In *Biometric Technology for Human Identification II*, volume 5779, pages 105–113. International Society for Optics and Photonics.
- Li, J., Feng, J., and Kuo, C.-C. J. (2018). Deep convolutional neural network for latent fingerprint enhancement. *Signal Processing: Image Communication*, 60:52–63.
- Lim, E., Jiang, X., and Yau, W. (2002). Fingerprint quality and validity analysis. In *Image Processing. 2002. Proceedings. 2002 International Conference on*, volume 1, pages I–I. IEEE.

- Maio, D. and 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., and Prabhakar, S. (2009). *Handbook of fingerprint recognition*. Springer Science & Business Media.
- Marcialis, G. L., Roli, F., and Serrau, A. (2007). Graph-based and structural methods for fingerprint classification. In *Applied Graph Theory in Computer Vision and Pattern Recognition*, pages 205–226. Springer.
- Marques, O. and Vieira Neto, H. (1999). *Processamento Digital de Imagens*. Brasport.
- Mittal, Y., Varshney, A., Aggarwal, P., Matani, K., and Mittal, V. (2015). Fingerprint biometric based access control and classroom attendance management system. pages 1–6.
- Msiza, I. S., Mathekga, M. E., Nelwamondo, F. V., and 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.
- Nguyen, D., Cao, K., and Jain, A. K. (2018). Automatic latent fingerprint segmentation. In *2018 IEEE 9th International Conference on Biometrics Theory, Applications and Systems (BTAS)*, pages 1–9.
- Niwattanakul, S., Singthongchai, J., Naenudorn, E., and Wanapu, S. (2013). Using of jaccard coefficient for keywords similarity. In *Proceedings of the International MultiConference of Engineers and Computer Scientists*, volume 1, page 6.
- 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*.

- Phromsuthirak, K. and Areekul, V. (2013). Fingerprint quality assessment using frequency and orientation subbands of block-based fourier transform. In *Biometrics (ICB), 2013 International Conference on*, pages 1–7. IEEE.
- Raff, E. (2018). Neural fingerprint enhancement. In *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, pages 118–124.
- Ratha, N. K., Chen, S., and Jain, A. K. (1995). Adaptive flow orientation-based feature extraction in fingerprint images. *Pattern Recognition*, 28(11):1657–1672.
- Rojas, V., Aching, S., Jorge, L., et al. (2006). An improved method for segmentation of fingerprint images. In *Electronics, Robotics and Automotive Mechanics Conference, 2006*, volume 2, pages 20–23. IEEE.
- Ross, A. A., Nandakumar, K., and Jain, A. (2006). *Handbook of multibiometrics*, volume 6. Springer Science & Business Media.
- Sabhanayagam, T., Venkatesan, V. P., and SenthamaraiKannan, K. (2018). A comprehensive survey on various biometric systems. In *International Journal of Applied Engineering Research*, pages 2276–2297.
- Sanchez-Reillo, R. and Mueller, R. (2015). *Finger Data Interchange Format, Standardization*, pages 551–561. Springer US, Boston, MA.
- Sankaran, A., Jain, A., Vashisth, T., Vatsa, M., and Singh, R. (2017). Adaptive latent fingerprint segmentation using feature selection and random decision forest classification. *Information Fusion*, 34:1–15.
- Shen, L., Kot, A., and Koo, W. (2001a). Quality measures of fingerprint images. In *Audio- and Video-based Biometric Person Authentication*, pages 266–271. Springer.
- Shen, L., Kot, A., and Koo, W. (2001b). Quality measures of fingerprint images. In *International Conference on Audio-and Video-Based Biometric Person Authentication*, pages 266–271. Springer.
- Shen, W. and Eshera, M. (2004). Feature extraction in fingerprint images. In *Automatic fingerprint recognition systems*, pages 145–181. Springer.

- Sherlock, B. G., Monro, D., and Millard, K. (1994). Fingerprint enhancement by directional fourier filtering. In *Vision, Image and Signal Processing, IEE Proceedings-*, volume 141, pages 87–94. IET.
- Shu, S.-G., Lin, H.-H., Kuo, S.-W., and Yu, S.-S. (2009). Excluding background initial segmentation for radiographic image segmentation.
- Stojanović, B., Marques, O., Nešković, A., and Puzović, S. (2016). Fingerprint roi segmentation based on deep learning. In *2016 24th Telecommunications Forum (TELFOR)*, pages 1–4.
- Sutthiwichaiorn, P., Areekul, V., and Jirachaweng, S. (2010). Iterative fingerprint enhancement with matched filtering and quality diffusion in spatial-frequency domain. In *Pattern Recognition (ICPR), 2010 20th International Conference on*, pages 1257–1260. IEEE.
- Tabassi, E., Wilson, C., and Watson, C. (2004). *Fingerprint Image Quality*. National Institute of Standards and Technology.
- Tang, Y., Gao, F., Feng, J., and Liu, Y. (2017). Fingernet: An unified deep network for fingerprint minutiae extraction. In *2017 IEEE International Joint Conference on Biometrics (IJCB)*, pages 108–116.
- Thai, D. H. and Gottschlich, C. (2016). Global variational method for fingerprint segmentation by three-part decomposition. *IET Biometrics*, 5(2):120–130.
- Thai, D. H., Huckemann, S., and Gottschlich, C. (2016). Filter design and performance evaluation for fingerprint image segmentation. *PloS one*, 11(5):e0154160.
- Turrone, F., Cappelli, R., and Maltoni, D. (2012). Fingerprint enhancement using contextual iterative filtering. In *Biometrics (ICB), 2012 5th IAPR International Conference on*, pages 152–157. IEEE.
- Važan, R. (2009). Sourceafis project.
- Wu, C., Tulyakov, S., and Govindaraju, V. (2007). Robust point-based feature fingerprint segmentation algorithm. In *International Conference on Biometrics*, pages 1095–1103. Springer.

- Yao, Z., Charrier, C., Rosenberger, C., et al. (2015). Quality assessment of fingerprints with minutiae delaunay triangulation. In *Information Systems Security and Privacy (ICISSP), 2015 International Conference on*, pages 315–321. IEEE.
- Yao, Z., Le Bars, J.-M., Charrier, C., and Rosenberger, C. (2016). Literature review of fingerprint quality assessment and its evaluation. *IET Biometrics*, 5(3):243–251.
- Zhao, F. and Tang, X. (2007). Preprocessing and postprocessing for skeleton-based fingerprint minutiae extraction. *Pattern Recognition*, 40(4):1270 – 1281.
- Zhu, E., Zhang, J.-m., Yin, J.-p., Zhang, G.-m., and Hu, C.-f. (2006). Removing the remaining ridges in fingerprint segmentation. *Journal of Zhejiang University-SCIENCE A*, 7(6):976–983.
- Zhu, Y., Yin, X., Jia, X., and Hu, J. (2017). Latent fingerprint segmentation based on convolutional neural networks. In *2017 IEEE Workshop on Information Forensics and Security (WIFS)*, pages 1–6.