

Extração de Minúcias em Imagens de Impressões Digitais utilizando Redes Neurais

Airam Carlos Pais Barreto Marques

Dissertação de Mestrado apresentada ao Curso de Mestrado em Ciência da Computação do Núcleo de Computação Eletrônica da Universidade Federal do Rio de Janeiro, como requisito parcial para a obtenção de grau de mestre.

Orientador: Antonio Carlos Gay Thomé – Ph.D.

Rio de Janeiro

2004

Extração de Minúcias em Imagens de Impressões Digitais utilizando Redes Neurais

Airam Carlos Pais Barreto Marques

Dissertação submetida ao corpo docente do Núcleo de Computação Eletrônica da Universidade Federal do Rio de Janeiro - UFRJ, como parte dos requisitos necessários à obtenção do grau de Mestre.

Aprovada por:

Prof. _____ - Orientador

Antônio Carlos Gay Thomé – Ph. D.

Prof. _____

Elder Moreira Hemerly – Ph. D.

Prof. _____

Felipe Maia Galvão França – Ph. D.

Prof. _____

Adriano Joaquim de Oliveira Cruz – Ph. D.

Rio de Janeiro

2004

M357 Marques, Airam Carlos Pais Barreto.

Extração de minúcias em impressões digitais / Airam Carlos Pais Barreto Marques. – Rio de Janeiro, 2004. xxiii, 155f.; il.

Dissertação (Mestrado em Informática) – Universidade Federal do Rio de Janeiro, Instituto de Matemática, Núcleo de Computação Eletrônica, 2004.

Orientador: Antônio Carlos Gay Thomé

1. Impressões Digitais – Teses. 2. Reconhecimento de Padrões. – Teses. 3. Segmentação – Teses. 4. Redes Neurais – Teses. I. Thomé, Antônio Carlos Gay (Orient.). II. Universidade Federal do Rio de Janeiro. Instituto de Matemática. Núcleo de Computação Eletrônica. III. Título

CDD

A Deus e a todos que me apoiaram durante este estudo.

*À minha mãe e a meus familiares que nunca me deixaram
desanimar mesmo nos momentos mais difíceis.*

AGRADECIMENTOS

Primeiramente agradeço a Deus, pois sem ele nada do que é poderia ser, muito menos esta simples dissertação.

Agradeço a toda a minha família, principalmente à minha mãe, pois sempre me apoiou em meus estudos e em todas as áreas da minha vida.

Não posso deixar de agradecer também aos meus amigos e amigas que me apoiaram a fazer este curso de mestrado, não só dando conselhos a fim de enriquecer o meu estudo, mas também através de momentos de descontração e amizade. Agradeço de forma especial ao meu orientador, pois sempre me deu o suporte técnico para o desenvolvimento deste trabalho além de ter demonstrado ser uma pessoa de extrema paciência para lidar com alguém tão limitado como eu.

Agradeço também ao NCE pelo suporte financeiro e pelos recursos físicos que são disponibilizados para todos os alunos, principalmente sabendo que em nosso país o apoio financeiro dado às instituições de ensino público é extremamente limitado.

RESUMO

MARQUES, Airam Carlos Pais Barreto. **Extração de Minúcias em Imagens de Impressões Digitais utilizando Redes Neurais**. Orientador: Antônio Carlos Gay Thomé. Rio de Janeiro: UFRJ/IM-NCE, 2004. Dissertação (Mestrado em Ciência da Computação).

Neste trabalho foram investigadas técnicas que utilizam redes neurais artificiais para o processamento de imagens de impressões digitais. Foram feitas propostas para as três principais sub-fases do processo de extração automática de minúcias, a saber, pré-processamento, segmentação da região de interesse e a extração de minúcias em si. Na fase de pré-processamento foram propostos dois métodos: um para equalização de histograma de forma adaptativa e um modelo neural para aproximar o filtro de Gabor com um custo computacional mais baixo do que a implementação tradicional do filtro. Para a fase de segmentação da região de interesse foi proposto um modelo neural para detectar as regiões da imagem que contém impressões digitais. Para a última fase, de detecção de minúcias, foi proposto um modelo que utiliza o filtro de Gabor complexo para a detecção das regiões com probabilidade de conter minúcias e uma rede neural que classifica cada região candidata como sendo ou não uma minúcia. Os resultados de cada proposta são apresentados assim como a sua avaliação através de critérios visuais e métricos.

ABSTRACT

MARQUES, Airam Carlos Pais Barreto. **Extração de Minúcias em Imagens de Impressões Digitais utilizando Redes Neurais.** Orientador: Antônio Carlos Gay Thomé. Rio de Janeiro: UFRJ/IM-NCE, 2004. Dissertação (Mestrado em Ciência da Computação).

In this work, techniques that employ artificial neural networks in the processing of fingerprint images were investigated. Approaches to the 3 main sub-phases of the minutiae extraction process (pre-processing, segmentation of the region of interest and the minutiae extraction itself) are proposed. For the pre-processing phase the proposals are: a method of adaptative histogram equalization and a neural model to perform Gabor filtering with a lower computational cost. For the segmentation phase, a neural model to identify the regions of the image which contain fingerprint fragments is proposed. For the last phase, the minutiae detection, the proposals are a model that employs the complex Gabor filter in the detection of the regions containing minutiae and a neural network that classifies each candidate region as minutia or not. The results for each proposal are presented as is their evaluation through visual and metrical criteria.

LISTA DE SIGLAS

AFIS	- Automated Fingerprint Identification System (Sistema Automático de Identificação por Impressões Digitais)
<i>ca</i>	- Coeficiente de Acerto
<i>ce</i>	- Coeficiente de Erro
<i>cq</i>	- Coeficiente de Qualidade
FM	- False Match (Falsa Positivização)
FMR	- False Match Rate (Taxa de Falsa Positiva)
FNM	- False Non-Match (Falsa Negativização)
FNMR	- False Non-Match Rate (Taxa de Falsa Negativização)
FTC	- Failure to Capture (Falha na Captura)
FTE	- Failure to Enroll (Falha no Cadastro)
GNC	- Gabor Neural Complexo
MB	- Mapa de Bits
MBCA	- Mapa de Bits com Correção de Ângulo
MBCAS	- Mapa de Bits com Correção de Ângulo Suavizado
<i>mc</i>	- Minúcias Candidatas
<i>mcr</i>	- Minúcias Candidatas Reais
<i>mr</i>	- Minúcias Reais
MVN	- Módulo de Validação Neural
NIST	- National Institute of Standards and Technology (Instituto norte-americano de padrões e tecnologia)
<i>NMGT</i>	- Número de Multiplicações do Gabor Tradicional
<i>NMGN</i>	- Número de Multiplicações do Gabor Neural
<i>NSGN</i>	- Número de Somas do Gabor Neural
<i>NSGT</i>	- Número de somas do Gabor Tradicional

P_C	- Probabilidade de Correspondência
P_{CM}	- Probabilidade de Correspondência Múltipla
P_{CME}	- Probabilidade de Correspondência Múltipla Exata
$pmcf$	- Percentual de Minúcias Candidatas Falsas
$pmcr$	- Percentual de Minúcias Candidatas Reais
pmf	- Percentual de Minúcias Falsas
pmv	- Percentual de Minúcias Verdadeiras

LISTA DE FIGURAS

Figura 2.1 – Processo de cadastramento em um sistema biométrico.....	7
Figura 2.2 – Curva de genuínos e impostores.....	11
Figura 2.3 – Curva de genuínos e impostores.....	12
Figura 2.4 – Curva ROC.....	13
Figura 2.5 – O rosto de uma pessoa (a) e a localização dos olhos, boca e nariz (b).....	14
Figura 2.6 – Resultados do localizador de faces proposto em (ROWLEY, BALUJA, KANADE, 1998).....	19
Figura 2.7 – Um olho humano visto a uma distância aproximada de 35 cm.....	20
Figura 2.8 – Radiografia dos dentes de uma vítima (a) e sua radiografia tirada enquanto ainda estava viva (b).....	21
Figura 2.9 – Imagem de um dente onde o usuário demarcou sua posição através de um retângulo, e marcou a posição da coroa com um ponto.....	21
Figura 2.10 – Contorno extraído do dente da Figura 2.9.....	22
Figura 2.11 – Aparelho de captura da imagem da mão.....	23
Figura 2.12 – Curva ROC obtida pelo método apresentado em (JAIN, PANKANTI, ROSS, 1999).....	23
Figura 2.13 – Imagem de uma impressão digital colhida com tinta sobre um pedaço de papel.....	24
Figura 2.14 – Tipos de minúcias. (a) fim-de-linha; (b) bifurcação.....	24
Figura 2.15 – Imagem da mesma impressão digital exibida na Figura 2.13. Observe os vários elementos que também se encontram na imagem e não fazem parte da digital.....	25
Figura 3.1 – Impressão digital de um polegar colhida sobre um pedaço de papel.....	28
Figura 3.2 – Imagem de um ápice, que é um padrão no fluxo das linhas, onde as linhas parecem dar meia-volta.....	29

Figura 3.3 – Imagem de um delta, que é caracterizado pelo fato de parecer que o fluxo das linhas formam um triângulo.....	30
Figura 3.4 – Alguns tipos de classes utilizadas para classificar impressões digitais. (a) Arco, (b) Presilha Interna, (c) Presilha Externa e (d) Verticilo.....	31
Figura 3.5 – Uma impressão digital com alguns poros.....	32
Figura 3.6 – Tipos de minúcias, fim-de-linha (a) e bifurcação (b).....	32
Figura 3.7 – Imagem de uma impressão digital latente encontrada na cena de um crime.....	33
Figura 3.8 – Imagem de um fragmento de impressão digital (esquerda) e o resultado obtido após o processo de binarização (direita).....	36
Figura 3.9 – (a) Fragmento binarizado de uma impressão digital. (b) Resultado do processo de afinamento aplicado em (a).....	36
Figura 3.10 – Imagem de uma impressão digital de boa qualidade.....	37
Figura 3.11 – Imagem de uma impressão digital de baixa qualidade.....	38
Figura 3.12 – Linhas de uma impressão digital vistas como um sólido tri-dimensional, onde o tom de cinza da imagem representa a altura da superfície.....	39
Figura 3.13 – Conjuntos nebulosos que definem se uma região é clara ou escura de acordo com o nível de cinza.....	40
Figura 3.14 – Janelas utilizadas pelo sistema de regras nebuloso proposto em (SAGAR, NGO, FOO, 1995) para determinar a presença de uma minúcia.....	41
Figura 3.15 – Imagem de um fim-de-linha obtida através da equação 3.1.....	43
Figura 3.16 – Ilustração dos elementos que serão utilizados para a computação da probabilidade de ocorrer uma correspondência entre dois conjuntos de minúcias.....	46
Figura 3.17 – Gráfico de P_{cm} para diferentes quantidades de minúcias envolvidas.....	50
Figura 4.1 – Imagem de uma impressão digital.....	52
Figura 4.2 – Histograma da imagem da Figura 4.1.....	53
Figura 4.3 – (a) Imagem clara de baixo contraste. (b) Imagem escura de baixo contraste.....	54

Figura 4.4 – (a) Histograma da Figura 4.3(a).....	54
Figura 4.5 – Da esquerda para a direita tem-se a distribuição da variável x, a definição da variável y e a distribuição de probabilidade de y.....	55
Figura 4.6 – (a) Imagem da Figura 4.3(a) após a equalização. (b) Imagem da Figura 4.3(b) após a equalização.....	56
Figura 4.7 – Histogramas das figuras 4.6(a) e (b) respectivamente.....	57
Figura 4.8 – Esta imagem possui regiões com bom contraste entre o fundo e as linhas da impressão digital e possui regiões escuras e claras de baixo contraste.....	58
Figura 4.9 – Imagem da Figura 4.8 após a equalização.....	58
Figura 4.10 – (a) Histograma da Figura 4.8. (b) Histograma da Figura 4.9, que é a imagem da Figura 4.8 após o processo de equalização.....	59
Figura 4.11 – Imagem da Figura 4.8 após a equalização local utilizando, como sub-imagens, blocos não superpostos de 16x16 pixels.....	60
Figura 4.12 – Imagem da Figura 4.8 após a equalização local aplicada somente nas regiões que fazem parte da impressão digital.....	61
Figura 4.13 – (a) Histograma da imagem da Figura 4.9 que é uma imagem equalizada. (b) Histograma da imagem da Figura 4.11 que é uma imagem equalizada localmente.....	61
Figura 4.14 – Imagem da Figura 4.11. Observe como o fragmento ampliado apresenta um aspecto quadriculado.....	62
Figura 4.15 – Na equalização local a imagem é dividida em blocos que são identificados por suas posições horizontal e vertical.....	63
Figura 4.16 – Ilustração gráfica das notações para a explicação da equalização local interpolada.....	64
Figura 4.17 – Imagem da Figura 4.8 após a equalização local interpolada.....	65
Figura 4.18 – Histograma da imagem da Figura 4.17, observe que se aproxima de uma distribuição uniforme.....	65
Figura 4.19 – (a) Imagem da Figura 4.8, com regiões de baixo contraste. (b) Imagem de (a) após a equalização local interpolada.....	66

- Figura 4.20 – À esquerda um fragmento da imagem 4.8 equalizada localmente, à direita o mesmo fragmento após a equalização local interpolada..... 66
- Figura 4.21 – Resposta ao impulso do filtro de Gabor no intervalo $[-15:15,-15:15]$, utilizando $g_x = g_y = 4$ e $f = 1/10$67
- Figura 4.22 – (a) Imagem de uma senóide com frequência $1/10$. (b) Imagem da senóide após a convolução com o filtro, o contraste foi aumentado.....68
- Figura 4.23 – (a) Corte de uma senóide bidimensional. (b) Resposta do filtro ao sinal de (a), o sinal foi realçado aumentando a amplitude da senóide. (c) A senóide (b) deve ser truncada, criando um sinal semelhante a um sinal quadrado.....69
- Figura 4.24 – (a) Imagem da Figura 4.22 (a) com alguns ruídos. (b) A imagem após a convolução com o filtro de Gabor.....69
- Figura 4.25 – À esquerda é exibida a transformada de Fourier de $W(x,y)$ que consiste em um filtro passa-baixa. À direita está a transformada de $V(y,f)$ que é um cosseno de frequência $f = 0.1$70
- Figura 4.26 – Gráfico da transformada de Fourier de $G(x,y,f)$, com frequência $f = 0.1$. O resultado é um filtro passa-banda com auge da banda passante nos pontos 0.1 e -0.1 (valor da frequência).....71
- Figura 4.27 – À esquerda é exibido um fragmento de uma impressão digital, observe como é semelhante a senóide à direita.....71
- Figura 4.28 – (a) Imagem de um fragmento de impressão digital. (b) Imagem filtrada por um filtro de Gabor com frequência $f = 1/14$71
- Figura 4.29 – (a) Fragmento de uma impressão digital. (b) Imagem filtrada com o filtro de Gabor com frequência $f = 1/5$72
- Figura 4.30 – (a) Fragmento de uma impressão digital onde as linhas oscilam horizontalmente. (b) Imagem resultante da filtragem de (a) com o filtro de Gabor de frequência $f = 1/14$. As linhas da imagem foram descaracterizadas.....73
- Figura 4.31 – Linhas de uma impressão digital e o ângulo θ que elas fazem com eixo x73

Figura 4.32 – (a) Imagem de um fragmento de impressão digital cujas linhas se assemelham a uma senóide que oscila ao longo do eixo x . (b) Aplicação do filtro de Gabor com $f = 1/14$ e $\theta = 900$	74
Figura 4.33 – Como o método proposto em (HONG, WAN, JAIN, 1998) obtém a x-signature.....	75
Figura 4.34 – (a) Um fragmento de impressão digital. (b) Imagem de (a) equalizada com o algoritmo da Seção 4.1. (c) Resultado do filtro de Gabor proposto em (HONG, WAN, JAIN, 1998) aplicado à imagem de (b).....	76
Figura 4.35 – (a) Um fragmento de impressão digital. (b) Imagem de (a) equalizada com o algoritmo da Seção 4.1. (c) Resultado do filtro de Gabor proposto em (HONG, WAN, JAIN, 1998) aplicado à imagem de (b).....	76
Figura 4.36 – O eixo r é ortogonal à direção θ do filtro. Os pontos (x_0, y_0) e (x_1, y_1) são simétricos a r , portanto $Gr(x_0, y_0, f, \theta) = Gr(x_1, y_1, f, \theta)$	77
Figura 4.37 – (a) Imagem de um fragmento de impressão digital. (b) Imagem após a aplicação do filtro G_i . (c) Imagem após a aplicação do filtro G_r	78
Figura 4.38 – (a) Fragmento de uma impressão digital. (b) Imagem obtida através do módulo da convolução de (a) com o filtro G_c	79
Figura 4.39 – Sinal filtrado com o gabor complexo. A parte real e imaginária são idênticas a não ser por um deslocamento de $1/4$ de seu período.....	79
Figura 4.40 – Imagem em que a metade da esquerda consiste em uma senóide e a metade da direita uma senóide igual com fase deslocada de π radianos.....	80
Figura 4.41 – Imagem obtida através do valor absoluto da imagem da Figura 4.40 aplicada ao filtro G_c	80
Figura 4.42 – Imagem de um fragmento de impressão digital com um fim-de-linha no centro. O lado direito e esquerdo da minúcia são parecidos com senóides de mesma frequência, mas com fases diferentes.....	81
Figura 4.43 – Imagem da Figura 4.42 após a aplicação do filtro de Gabor complexo com orientação de zero grau.....	81

Figura 4.44 – (a) Uma senóide com período 7, fase 0 e sem ruído. (b) Uma senóide sem ruído, com fase 450 e período 10. (c) Uma senóide igual a (b) com ruído oscilando entre -32 e 32.....	84
Figura 4.45 – De cima para baixo estão, a imagem original, a imagem filtrada com o método proposto, a imagem filtrada com o filtro convencional de 17x17 pixels e a imagem filtrada com 13x13 pixels.....	86
Figura 4.46 – Fragmento de impressão digital com seu respectivo filtro de Gabor utilizando o método proposto nesta seção.....	87
Figura 4.47 – Fragmento de impressão digital com seu respectivo filtro de Gabor utilizando o método proposto nesta seção.....	87
Figura 4.48 – A imagem da esquerda é um fragmento de impressão digital, e a imagem da direita é a imagem filtrada com o método proposto utilizando a equação 4.11.....	88
Figura 5.1 – Imagem de uma impressão digital colhida em uma ficha de identificação. Observe os vários elementos que também se encontram na imagem e não fazem parte da digital.....	92
Figura 5.2 – (a) Imagem de um fragmento de impressão digital; (b) Imagem de uma senóide bidimensional com mesma direção de (a).....	94
Figura 5.3 – (a) Imagem de uma impressão digital; (b) Espectro de Fourier de (a). Existe um anel onde se concentra energia.....	94
Figura 5.4 – (a) Espectro de Fourier da Figura 5.2(a); (b) Espectro de Fourier da Figura 5.2(b).....	95
Figura 5.5 – (a) Imagem de um fragmento de impressão digital; (b) Espectro de Fourier de (a) sem o componente central; (c) Vetor de características obtido do espectro de Fourier da imagem (c).....	97
Figura 5.6 – Imagem de um fragmento que não é uma impressão digital, seu espectro de Fourier sem o componente central e seu vetor de características obtido do espectro de Fourier da imagem.....	98
Figura 5.7 – Método de interpolação bilinear que é aplicado nas matrizes N1 e N2 para se preencher os pixels que não são centros de nenhuma janela.....	100

Figura 5.8 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.....	101
Figura 5.9 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.....	101
Figura 5.10 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.....	101
Figura 5.11 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.....	102
Figura 5.12 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.....	102
Figura 5.13 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.....	102
Figura 5.14 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.....	103
Figura 5.15 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.....	106
Figura 5.16 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.....	107
Figura 5.17 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.....	108
Figura 5.18 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.....	109
Figura 5.19 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.....	110

Figura 5.20 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.....	111
Figura 5.21 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.....	112
Figura 6.1 – Ilustração básica do funcionamento do extrator de minúcias.....	114
Figura 6.2 – A imagem da esquerda é um fragmento de impressão digital, e a imagem da direita é a imagem filtrada com o método proposto na Seção 4.4.....	115
Figura 6.3 – A imagem à esquerda é o resultado da aplicação do filtro de Gabor na imagem da Figura 4.48, e a imagem à direita é o resultado de sua binarização com um limiar de corte $L=100$	115
Figura 6.4 – (a) Imagem binarizada após a filtragem com o filtro de Gabor. (b) Imagem com os centros de cada uma das regiões conexas obtidas aplicando-se o algoritmo de rotulação em (a).....	116
Figura 6.5 – Esta figura ilustra como é calculado o ângulo da minúcia.....	117
Figura 6.6 – (a) Fragmento de uma imagem de uma impressão digital filtrada com o filtro de Gabor, a seta indica a direção estimada de um ponto candidato a ser minúcia. (b) Vetor de características extraído, uma imagem de 27 x 17 pixels.....	118
Figura 6.7 – (a) Fragmento de uma bifurcação, a seta indica a direção estimada da minúcia. (b) Vetor de características extraído, uma imagem de 27 x 17 pixels.....	119
Figura 6.8 – (a) Fragmento de uma não-minúcia, a seta indica a direção estimada caso fosse uma minúcia. (b) Vetor de características extraído, uma imagem de 27 x 17 pixels.....	119
Figura 6.9 – Extração do mapa de bits de uma bifurcação que se encontra em uma região de curva.....	120
Figura 6.10 – (a) Mapa de bits extraído da bifurcação da imagem da Figura 6.9. (b) Mapa de bits com ângulo corrigido extraído da mesma bifurcação.....	120
Figura 6.11 – A figura acima exhibe uma linha de um MBCA com 27 posições. A figura abaixo exhibe as 9 médias extraídas da linha.....	121

Figura 6.12 – Imagem obtida do arquivo NIST, código U295. Esta imagem possui boa qualidade, as linhas estão pouco falhadas e há um bom contraste entre linhas e fundo.....	122
Figura 6.13 – Imagem de código U238 do arquivo NIST. Esta imagem é de má qualidade, pois possui linhas muito falhadas e apesar do contraste não ser muito baixo.....	122
Figura 6.14 – Imagem de código G099 do arquivo NIST. Esta imagem é de péssima qualidade, pois o contraste é muito baixo e as linhas estão muito falhadas.....	123
Figura 6.15 – Matriz de treinamento de uma rede neural.....	124
Figura 6.16 – Os 4 blocos que são percorridos para cada ponto candidato de coordenada (x,y)	128
Figura 6.17 – Minúcias extraídas da Imagem U295 (boa qualidade) utilizando-se o MVN02, que possui a menor <i>PFM</i>	143
Figura 6.18 – Minúcias extraídas da Imagem U238 (má qualidade) utilizando-se o MVN02, que possui a menor <i>PFM</i>	144
Figura 6.19 – Minúcias extraídas da Imagem G099 (péssima qualidade) utilizando-se o MVN02, que possui a menor <i>PFM</i>	145
Figura 7.1 – (a) Imagem de uma impressão digital; (b) Histograma de (a).....	151
Figura 7.2 – (a) Imagem da impressão digital da Figura 7.1(a) após a equalização local interpolada; (b) Histograma de (a).....	151
Figura 7.3 – (a) Imagem de uma impressão digital; (b) Imagem resultante do método de segmentação proposto no Capítulo 5.....	152
Figura 7.4 – (a) Imagem de um fim-de-linha; (b) Imagem de uma bifurcação; (c) Imagem de uma região que não é minúcia.....	153
Figura 7.5 – Imagem de uma impressão digital com suas minúcias detectadas pelo método proposto no Capítulo 6.....	154

LISTA DE TABELAS

Tabela 2.1 – Comparação entre alguns tipos de dados biométricos (JAIN, ROSS, PRABHAKAR, 2004).....	27
Tabela 4.1 – Comparação do tempo de processamento entre o método proposto e os filtros de Gabor com 13x13 e 17x17 pixels.....	89
Tabela 4.2 – Comparação do número de multiplicações e somas utilizadas pelo método proposto e o método tradicional.....	91
Tabela 5.1 – Coeficientes de acerto, erro e de qualidade para cada uma das imagens das figuras 5.8 a 5.14, obtidos através do segmentador proposto.....	104
Tabela 5.2 – Coeficientes de acerto, erro e qualidade para cada uma das imagens das figuras 5.8 a 5.14, obtidos através do segmentador proposto, utilizando as operações de <i>fechamento e abertura</i>	105
Tabela 6.1 – Resultados do GNC testados com diferentes valores de corte L	127
Tabela 6.2 – Lista das combinações de extração de características e uso do PCA. Cada combinação possui um nome, totalizando 11 combinações diferentes.....	130
Tabela 6.3 – Matriz de confusão da base de treinamento sobre a base B_MB, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 98.5%.....	131
Tabela 6.4 – Matriz de confusão da base de validação sobre a base B_MB, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 96.24%.....	131
Tabela 6.5 – Matriz de confusão da base de teste sobre a base B_MB, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 95.73%.....	132
Tabela 6.6 – Matriz de confusão da base de treinamento sobre a base B_MBCA, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 98.18%.....	132
Tabela 6.7 – Matriz de confusão da base de validação sobre a base B_MBCA, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 96.49%.....	132
Tabela 6.8 – Matriz de confusão da base de teste sobre a base B_MBCA, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 95.48%.....	133

Tabela 6.9 – Matriz de confusão da base de treinamento sobre a base B_MBCAS, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 98%.....	133
Tabela 6.10 – Matriz de confusão da base de validação sobre a base B_MBCAS, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 96.49%.....	133
Tabela 6.11 – Matriz de confusão da base de teste sobre a base B_MBCAS, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 95.73%.....	134
Tabela 6.12 – Matriz de confusão da base de treinamento sobre a base B_MBCAS, obtida pela rede FAM com $\rho = 0.2$ e $\beta = 0.5$. O índice de acerto geral foi de 95.74%.....	135
Tabela 6.13 – Matriz de confusão da base de validação sobre a base B_MBCAS, obtida pela rede FAM com $\rho = 0.2$ e $\beta = 0.5$. O índice de acerto geral foi de 95.48%.....	135
Tabela 6.14 – Matriz de confusão da base de teste sobre a base B_MBCAS, obtida pela rede FAM com $\rho = 0.2$ e $\beta = 0.5$. O índice de acerto geral foi de 94.73%.....	135
Tabela 6.15 – Matriz de confusão média do MVN utilizando a rede MLP com arquitetura 459x40x3 treinada com a base B_MB. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.....	138
Tabela 6.16 – Matriz de confusão média do MVN utilizando a rede MLP com arquitetura 459x40x3 treinada com a base B_MBCA. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.....	139
Tabela 6.17 – Matriz de confusão média do MVN utilizando a rede MLP com arquitetura 459x40x3 treinada com a base B_MBCAS. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.....	139
Tabela 6.18 – Matriz de confusão média do MVN utilizando a rede FAM com $\rho = 0.2$ e $\beta = 0.5$, treinada com a base B_MBCAS. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.....	139
Tabela 6.19 – Os tipos de MVN utilizados para testar o desempenho do extrator de minúcias. As redes utilizadas são as melhores destacadas na seção anterior.....	140
Tabela 6.20 – Percentuais médios de minúcias corretamente encontradas (pmv) e de minúcias falsas geradas (pmf), para cada tipo de MVN testado.....	140

Tabela 6.21 – Valores percentuais e absolutos de minúcias corretamente encontradas (<i>pmv</i>) e de minúcias falsas geradas (<i>pmf</i>), para cada tipo de MVN testado contra a imagem U295, que possui boa qualidade e 107 minúcias reais.....	141
Tabela 6.22 – Valores percentuais e absolutos de minúcias corretamente encontradas (<i>pmv</i>) e de minúcias falsas geradas (<i>pmf</i>), para cada tipo de MVN testado contra a imagem U238, que possui má qualidade e 97 minúcias reais.....	141
Tabela 6.23 – Valores percentuais e absolutos de minúcias corretamente encontradas (<i>pmv</i>) e de minúcias falsas geradas (<i>pmf</i>), para cada tipo de MVN testado contra a imagem G099, que possui péssima qualidade e 55 minúcias reais.....	141
Tabela 6.24 – Para cada tipo de MVN testado, são apresentados os valores de <i>q</i> (média de minúcias coincidentes), <i>m</i> (média de minúcias geradas) e <i>PFM</i> (probabilidade de ocorrer uma falsa correspondência entre dois conjuntos de minúcias).....	143
Tabela 6.25 – Valores percentuais de minúcias corretamente encontradas (<i>pmv</i>) e de minúcias falsas geradas (<i>pmf</i>), para o modelo tradicional e para o modelo proposto utilizando o MVN02.....	147

SUMÁRIO

AGRADECIMENTOS.....	v
RESUMO	vi
ABSTRACT	vii
LISTA DE SIGLAS	viii
LISTA DE FIGURAS	x
LISTA DE TABELAS	xix
SUMÁRIO.....	xxii
1 INTRODUÇÃO	1
1.1 Motivação	1
1.2 Métodos Propostos	2
1.3 Organização da Dissertação	4
2 BIOMETRIA	5
2.1 Sistemas Biométricos	5
2.2 Tipos de Biometria	15
2.2.1 DNA.....	16
2.2.2 Voz.....	17
2.2.3 Face.....	18
2.2.4 Íris	19
2.2.5 Dentes.....	20
2.2.6 Geometria das mãos.....	22
2.2.7 Impressões Digitais.....	23
2.3 Considerações Finais	26
3 IMPRESSÕES DIGITAIS.....	28
3.1 Formação e Características das Impressões Digitais.....	28
3.2 Extração Automática de Minúcias	34
3.2.1 Método Clássico	35
3.2.2 Métodos Não Clássicos.....	38
3.3 Individualidade das Impressões Digitais	44
3.4 Considerações Finais	51
4 TRATAMENTO DA IMAGEM.....	52
4.1 Equalização de Histograma.....	52
4.2 Equalização Local – Proposta de uma nova abordagem	62
4.3 Filtro de Gabor	66
4.4 Proposta de Aproximação do Filtro de Gabor através de uma Rede Neural ..	82
4.4.1 Treinamento.....	83
4.4.2 Implementação do filtro	85
4.4.3 Experimentos.....	85
4.4.4 Análise dos resultados e Conclusão.....	88
5 SEGMENTAÇÃO DA REGIÃO DE INTERESSE	92
5.1 Segmentação	92
5.2 Proposta de um novo Método de Segmentação	93
5.2.1 Subdivisão da Imagem e a Obtenção do Vetor de Características	93
5.2.2 A classificação Neural	98
5.2.3 Implementação da Segmentação	99
5.3 Experimentos e Resultados.....	101
5.4 Métrica para Avaliação de Desempenho	103

5.5	Pós-Processamento com Filtragem Morfológica	105
5.6	Conclusão	113
6	EXTRAÇÃO AUTOMÁTICA DE MINÚCIAS	114
6.1	Módulo GNC (Gabor Neural Complexo)	115
6.2	MVN (Módulo de Validação Neural)	117
6.2.1	Mapa de Bits (MB)	118
6.2.2	Mapa de Bits com Correção de Ângulo (MBCA)	119
6.2.3	Mapa de Bits com Correção de Ângulo Suavizado (MBCAS)	120
6.3	Testes e Resultados	121
6.3.1	PCA	123
6.3.2	Testes e Resultados do GNC	125
6.3.3	Testes e Resultados do MVN	128
6.3.4	Testes com as Imagens do NIST	136
6.3.5	Resultados do Extrator de Minúcias	139
6.4	Conclusões	145
7	CONCLUSÕES	148
7.1	Pré-processamento	150
7.2	Segmentação	152
7.3	Extração Automática de Minúcias	153
7.4	Trabalhos futuros	155
8	REFERÊNCIAS BIBLIOGRÁFICAS	156

1 INTRODUÇÃO

Biometria significa, literalmente, medida da vida e se refere à parte da ciência que estuda características biológicas, tanto físicas como comportamentais, que podem ser usadas para a identificação de pessoas.

Os seres humanos aprendem desde cedo a se reconhecerem basicamente pela aparência facial e corporal e pelo timbre da voz. Outros animais podem se reconhecer através de outros sentidos, como o olfato.

As pessoas assinam contratos por acreditarem que é difícil fazer uma cópia de sua assinatura, garantindo assim, um certo grau de segurança contra fraude. Conforme a criminalidade aumenta a biometria ganha mais importância, pois a identificação de pessoas, através de suas próprias características físicas, auxilia no processo de prevenção ou de solução de crimes.

Atualmente, devido ao avanço da ciência e da tecnologia, existem vários tipos de dados biométricos que podem ser utilizados em sistemas de segurança como, por exemplo, o DNA, o desenho da face, a íris, a retina, o jeito de uma pessoa andar, a geometria das mãos, as impressões digitais e outros.

O computador é a principal ferramenta para processamento de sistemas biométricos, por isso, vários pesquisadores têm proposto métodos computacionais para a manipulação e comparação de dados biométricos.

Esta dissertação apresenta um estudo sobre impressões digitais, uns dos dados biométricos mais utilizados em criminalística, e apresenta alguns métodos computacionais utilizados para a manipulação das mesmas.

As seções seguintes apresentam a motivação que levou a este estudo, um resumo dos métodos propostos e uma descrição de como o restante desta monografia está organizada.

1.1 Motivação

Para que características físicas possam ser utilizadas em um computador é necessário que haja um processo de coleta e digitalização das mesmas. A coleta é o

procedimento pelo qual o dado biométrico é extraído da pessoa e armazenado em algum meio físico, por exemplo, uma amostra de sangue ou saliva geralmente deve ser coletada para que se possa extrair o DNA de uma pessoa. A digitalização consiste na transformação do dado físico (analógico) em dado digital, por exemplo, uma impressão digital pode ser coletada utilizando-se tinta sobre o dedo e depois pressionando-o contra uma folha de papel, gerando assim, uma imagem que pode ser digitalizada através de um scanner óptico.

Tanto o processo de coleta quanto o de digitalização podem introduzir ruídos ao dado biométrico, introduzindo um desafio extra aos métodos computacionais de manipulação destes dados. Por exemplo, a pele humana é elástica, portanto, ao se coletar e digitalizar uma mesma impressão digital duas vezes, não implica dados digitais exatamente iguais. Portanto, é necessário que os algoritmos sejam robustos a este e outros tipos de distorções e ruídos.

As impressões digitais que estão presentes nas palmas das mãos, ponta dos dedos e planta dos pés, são formadas por várias linhas. Os pontos em que estas linhas terminam ou bifurcam são conhecidos como minúcias, e consistem em informações características muito utilizadas para identificação de impressões digitais.

A localização automática de minúcias em impressões digitais tem sido alvo de estudo para vários pesquisadores, porém, ainda não existe uma solução definitiva (MALTONI, MAIO, 1998), o que gera motivação para que mais pesquisas sejam feitas sobre este problema.

As minúcias de uma impressão digital possuem um padrão visual característico de fácil identificação por peritos humanos. As redes neurais artificiais são bem conhecidas por apresentarem bons resultados em problemas de reconhecimento de padrões, motivando assim, a investigação da hipótese de que seu uso, na solução deste problema, possa trazer benefícios no processo de localização de minúcias.

1.2 Métodos Propostos

O processo de localização automática de minúcias a partir da imagem de uma impressão digital envolve as seguintes fases:

- **Pré-processamento:** nesta fase são aplicados filtros sobre a imagem, com o objetivo de realçar a sua qualidade ou alguma característica;
- **Segmentação ou Detecção da Região de Interesse:** esta fase é responsável pela detecção da região da imagem que possui a impressão digital separando-a das demais regiões da imagem;
- **Extração de Características:** nesta fase ocorre a extração das minúcias;
- **Pós-processamento:** esta fase tem como objetivo refinar o resultado obtido da fase anterior, removendo eventuais características espúrias.

Para a fase de pré-processamento é feita a proposta de um método de equalização de histograma local interpolada, que consiste em uma modificação do método de equalização tradicional, visando aumentar o grau de uniformidade da equalização. Para a fase de pré-processamento é também proposta uma modificação no uso do filtro de Gabor tradicional (HONG, WAN, JAIN, 1998), através do uso de uma rede neural que se comporta como o filtro tradicional, porém utiliza menos computação.

Para a fase de Segmentação ou Detecção da Região de Interesse, é proposto um método neural que identifica as regiões que possuem impressão digital separando-as das demais regiões da imagem. Este modelo se baseia no fato de que fragmentos pequenos de impressões digitais se assemelham a funções senoidais bidimensionais (JAIN, PANKANTI, 1997) e, portanto, possuem um padrão em seu espectro de Fourier de fácil identificação.

Para a fase de Extração de Características é feita a proposta de um método baseado em redes neurais para a identificação das minúcias. Este método utiliza o filtro de Gabor complexo (LEUNG, ENGELER, FRANK, 1990) para identificar as regiões candidatas a terem minúcias, posteriormente, uma rede neural é utilizada em cada região candidata para identificar se há ou não uma minúcia e, caso haja, qual o seu tipo (fim-de-linha ou bifurcação).

1.3 Organização da Dissertação

O restante do texto está organizado da seguinte forma:

- **Capítulo 2:** exibe uma visão geral sobre biometria, abordando os principais tipos de dados biométricos utilizados, os métodos utilizados para sua manipulação e os desafios associados;
- **Capítulo 3:** este capítulo apresenta as impressões digitais, explicando a sua formação, a sua importância na identificação de pessoas e os problemas que devem ser levados em conta ao se confeccionar um método computacional para a extração de minúcias;
- **Capítulo 4:** neste capítulo são apresentados, dois filtros de processamento de imagens, propostas de melhoria nos seus usos e os resultados e conclusões;
- **Capítulo 5:** apresenta uma proposta para a segmentação da região de interesse de uma impressão digital;
- **Capítulo 6:** este capítulo apresenta o modelo de rede neural proposto para a extração automática de minúcias a partir da imagem de uma impressão digital;
- **Capítulo 7:** aqui é feito um resumo da dissertação e das conclusões dos capítulos 4, 5 e 6, apresentando algumas propostas de trabalhos futuros.

2 BIOMETRIA

Os seres humanos e outros animais utilizam características fisiológicas e comportamentais para reconhecerem uns aos outros. Por exemplo, as pessoas geralmente utilizam o desenho do rosto para identificar as outras pessoas.

Na primeira metade do século XIX Alphonse Bertillon, chefe da divisão de identificação criminal do departamento de polícia de Paris, desenvolveu e colocou em prática a idéia de utilizar uma série de medidas corporais para a identificação de criminosos (JAIN, ROSS, PRABHAKAR, 2004). Na segunda metade do mesmo século, Sir Francis Galton demonstrou que duas pessoas não possuem impressões digitais iguais. Com esses acontecimentos, as características biológicas passaram a receber maior importância, iniciando o seu estudo formal que recebeu o nome de Biometria.

A biometria, cujo significado literal é medida da vida, tem dois objetivos principais:

- o estudo de modelos matemáticos para a representação das características biológicas. Estes modelos são conhecidos como dados biométricos, que consistem basicamente em uma série de medidas (números) extraídas de uma determinada característica fisiológica ou comportamental;
- o estudo de métodos de comparação dos dados biométricos, cujo objetivo é comparar dois dados biométricos obtidos de uma mesma característica biológica e gerar como resultado um valor que indique se os dados biométricos foram obtidos do mesmo indivíduo ou não.

2.1 Sistemas Biométricos

Apesar da biometria ter suas raízes na área criminal, o seu uso em outras aplicações é importante, como nas seguintes áreas:

- **financeira**: um banco pode utilizar um dado biométrico para garantir que uma determinada transação está sendo efetuada pelo cliente ou por um impostor;
- **governamental**: o governo pode utilizar dados biométricos, como a impressão digital, para evitar fraudes, por exemplo, na emissão de documentos;

- **civil**: a utilização da biometria para aplicações como controle de acesso já está em uso em alguns sistemas de redes de computadores, em tais sistemas o usuário ao invés de fornecer uma senha, fornece um dado biométrico para efetuar a sua conexão na rede.

Apesar das aplicações mencionadas acima serem diferentes em natureza, todas elas possuem um ponto em comum que é a questão da segurança dos serviços prestados, ou seja, é necessária a certificação de que a pessoa que está usando o serviço é realmente um cliente ou usuário legítimo e não um impostor. Em aplicações dessa natureza é tradicionalmente feito um esquema onde o usuário, no momento do cadastro, é associado a uma assinatura, que por sua vez, consiste em um conjunto de informações que identificam o usuário de forma única. A seguir estão listados alguns tipos de assinaturas utilizadas:

- **assinatura usual**: consiste na assinatura tradicional utilizada em cheques bancários por exemplo, onde o banco certifica-se da autenticidade do documento através da forma como o seu cliente assina seu nome;

- **senha**: muito utilizada em esquemas de segurança de redes de computadores, a senha consiste em uma seqüência de caracteres que somente o usuário legítimo da rede conhece;

- **dados biométricos**: as características fisiológicas e comportamentais de uma pessoa podem consistir em uma assinatura, como por exemplo, o DNA, as impressões digitais, o desenho da face, a íris e outras.

Os sistemas de segurança que utilizam a biometria para identificar seus usuários ou clientes são conhecidos como sistemas biométricos. Um sistema biométrico possui basicamente 3 módulos, descritos a seguir:

- **base de padrões**: consiste em uma base de dados que contém os dados biométricos associados a cada usuário;

- **cadastro**: este módulo consiste basicamente no cadastro do cliente na base de dados, envolvendo também a coleta do dado biométrico do cliente e o controle da qualidade da coleta, que pode envolver um processo de re-coleta até que a qualidade mínima seja atingida. Este módulo envolve também os dispositivos necessários para a

coleta do dado biométrico, como câmeras de vídeo, scanners de impressões digitais ou de íris e outros. A Figura 2.1 exibe o processo de cadastro;

- **reconhecimento**: este módulo consiste no serviço real prestado pelo sistema biométrico, que é a certificação ou identificação do usuário através de seu dado biométrico.

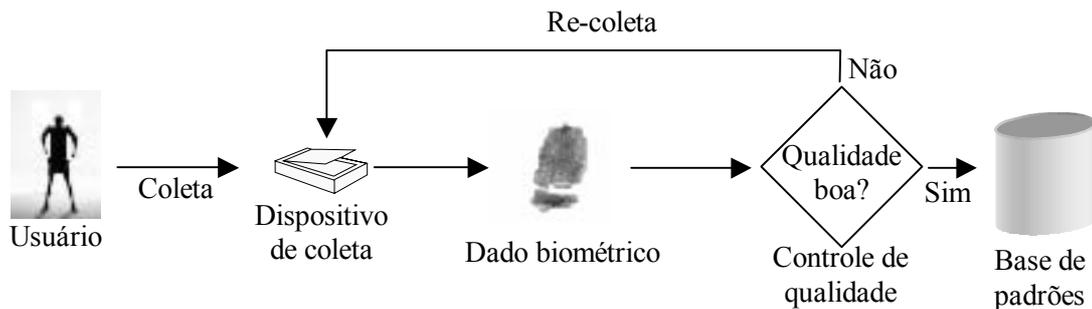


Figura 2.1 – Processo de cadastramento em um sistema biométrico. O usuário pode ter que refazer a coleta várias vezes até atingir o nível mínimo de qualidade.

Uma característica biológica pode ser utilizada como um dado biométrico contanto que satisfaça os seguintes requerimentos (JAIN, ROSS, PRABHAKAR, 2004):

- **Universalidade**: todas as pessoas devem possuir a característica;
- **Unicidade**: o dado biométrico extraído da característica deve fornecer informação suficiente para distinguir os indivíduos. Este requerimento está intimamente relacionado com a probabilidade de dois indivíduos possuírem dados biométricos iguais;
- **Coletável**: consiste na existência tanto do conhecimento como da tecnologia necessária para a extração de informação biométrica;
- **Imutabilidade**: a característica biométrica não deve mudar, ou mudar de forma não significativa, as suas propriedades ao longo do tempo.
- **Desempenho**: esta propriedade se refere tanto à precisão quanto a velocidade de comparação dos dados biométricos;
- **Aceitabilidade**: refere-se ao número de pessoas que se sentem à vontade em fornecer tal dado biométrico;

- **Facilidade de Fraude:** refere-se ao grau de facilidade com que alguém ou um grupo de pessoas pode burlar o sistema de forma fraudulenta.

Como mencionado anteriormente, o serviço oferecido por um sistema biométrico é o reconhecimento, que pode ser um serviço de certificação ou de identificação. A seguir é descrito cada um destes serviços:

- **certificação:** consiste em verificar se uma pessoa é quem ela afirma ser. Ou seja, um indivíduo J afirma ser a pessoa I . O sistema deve comparar o dado biométrico de J com o dado biométrico de I , que está na base de padrões e dizer se são iguais ou não;

- **identificação:** neste tipo de reconhecimento é fornecido ao sistema o dado biométrico, porém sem uma identidade. O sistema deve justamente descobrir quem é a pessoa associada ao dado biométrico fornecido, ou seja, deve compará-lo aos demais padrões armazenados na base.

Para ambos os tipos de reconhecimento é necessária a existência de um método, chamado de comparador, capaz de comparar dois dados biométricos e dizer se eles pertencem a um mesmo indivíduo ou não. Idealmente, é desejável que o comparador seja um algoritmo cuja resposta seja binária, *sim* ou *não* se os dados, respectivamente, forem ou não semelhantes. Um mesmo dado biométrico de uma mesma pessoa não se apresenta exatamente igual a cada coleta, isto se deve a ruídos presentes tanto nos dispositivos de coleta como na própria característica biológica. Os ruídos dos dispositivos de coleta ocorrem tanto pelo mau funcionamento de um dispositivo defeituoso, ou simplesmente pelo fato de não existir nenhum dispositivo completamente livre de ruído. Já os ruídos presentes na própria característica biológica podem ocorrer pelo fato dela estar sujeita a intempéries do dia a dia, por exemplo, um sistema baseado em voz pode não reconhecer uma pessoa que está com a voz rouca, ou um sistema baseado em impressões digitais pode não funcionar se uma pessoa expõe as mãos a produtos químicos cáusticos que acabam destruindo as impressões. Outro ruído presente na característica biológica é a própria mudança natural que pode ocorrer durante o processo de coleta, por exemplo, como a pele humana é elástica podem ocorrer

pequenas mudanças durante a fotografia de um rosto ou na coleta de uma impressão digital.

Devido a esses ruídos, um comparador deve ser uma função que recebe dois dados biométricos e gerar como saída um número indicando o grau de similaridade entre ambos. Dessa forma, durante o processo de reconhecimento é necessária a existência de um limiar β , de maneira que se o comparador retornar um valor maior ou igual a β os dados biométricos comparados são considerados como sendo da mesma pessoa.

Sejam D_I e D_J os dados biométricos das pessoas I e J respectivamente. Seja β o limiar mencionado anteriormente. Pode-se definir o processo de certificação da seguinte forma:

Certificação

$$\begin{cases} \text{usuário legítimo, se } \text{comparador}(D_I, D_J) \geq \beta \\ \text{impostor, caso contrário} \end{cases}$$

De forma semelhante, a identificação pode ser definida da seguinte maneira:

Identificação

$$\begin{cases} A \text{ pessoa está na base com identidade } J, \text{ se } \max_j(\text{comparador}(D_I, D_j)) \geq \beta \\ A \text{ pessoa não está na base, caso contrário} \end{cases}$$

Como o dado biométrico está sujeito a ruídos, podem ocorrer erros durante o processo de comparação. Para explicar melhor estes tipos de erro considere os seguintes termos relacionados à comparação de dois dados biométricos:

- **positivação ou comparação positiva:** este termo reflete o fato do comparador ter retornado um valor de semelhança maior ou igual ao limiar β , indicando que os dois dados biométricos comparados pertencem a mesma pessoa;
- **negativação ou comparação negativa:** este termo reflete justamente o oposto da positivação, ou seja, o comparador retornou um resultado com

valor inferior a β , criando a interpretação de que os dados biométricos não são da mesma pessoa.

Portanto, devido à presença de ruídos, existe a possibilidade do comparador gerar como saída um valor maior ou igual a β para dados biométricos extraídos de pessoas diferentes, ou pode ocorrer o contrário, o comparador retornar um valor inferior a β para dados biométricos extraídos da mesma pessoa. Esses dois tipos de erros são conhecidos respectivamente como falsa positivação e falsa negativação, que serão referenciados daqui por diante pelas respectivas siglas em inglês FM (*false match*) e FNM (*false non-match*). Estas siglas são adotadas neste texto apenas pelo fato delas serem utilizadas na maioria dos artigos sobre biometria.

A precisão de um sistema biométrico pode, portanto, ser medido através da taxa de ocorrência de FM e de FNM. É chamado de FMR (*false match rate*) a probabilidade de ocorrência de uma falsa positivação, e FNMR (*false non-match rate*) a probabilidade de ocorrer uma falsa negativação em um sistema biométrico.

É óbvio que ambas as taxas, FMR e FNMR, são dependentes do valor de limiar β , pois se este assumir um valor muito alto o valor de FNMR aumentará enquanto que, FMR aumentará conforme β diminui. O que se deseja é um valor de limiar que minimize as duas taxas de erros, o que é dependente da aplicação do sistema biométrico, por exemplo, para uma investigação criminal é importante escolher um valor para β que minimize a FNMR mesmo que aumente a FMR, pois é melhor que vários suspeitos do crime sejam analisados manualmente do que permitir que o verdadeiro criminoso não seja encontrado. Já em aplicações de controle de acesso, o importante é minimizar a FMR, pois o objetivo nesta aplicação é justamente impedir que um impostor tenha o acesso garantido, mesmo que isso possa aumentar a FNMR, impedindo que alguns usuários legítimos tenham acesso.

Para se determinar o melhor valor para β é necessário fazer uma análise estatística dos dados contidos na base do sistema biométrico. Uma análise estatística muito utilizada é o gráfico da curva de genuínos contra impostores. A curva de genuínos consiste na distribuição de probabilidade dos valores de retorno do comparador para pares de dados biométricos pertencentes à mesma pessoa. A curva de impostores é a distribuição de probabilidade dos valores de retorno do comparador para pares de dados

biométricos de pessoas diferentes. Para formalizar matematicamente estas definições assumamos as seguintes notações:

$Score$ – denota valor retornado pelo comparador.

H_0 – evento em que dois dados biométricos pertencem à mesma pessoa.

H_1 – evento em que dois dados biométricos não pertencem à mesma pessoa.

$P(s/H_0)$ – probabilidade de o score ter o valor s dado H_0 .

$P(s/H_1)$ – probabilidade de o score ter o valor s dado H_1 .

Com essas notações, a curva de genuínos pode ser definida como a distribuição de $P(s/H_0)$ para cada $score$ possível. De forma análoga, a curva de impostores pode ser definida pela distribuição $P(s/H_1)$. A Figura 2.2 exibe um exemplo das curvas de genuínos e impostores.

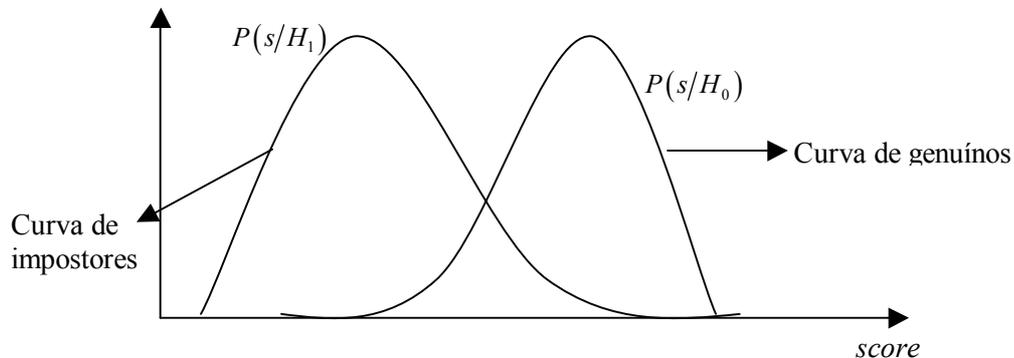


Figura 2.2 – Curva de genuínos e impostores. Observe que a curva de genuínos se concentra nas regiões de maior $score$ enquanto que a de impostores nas regiões onde o $score$ é menor.

Obviamente espera-se que a curva de genuínos seja mais concentrada nas regiões em que os valores de $score$ sejam mais altos, pois o comparador tende a retornar valores altos para pares de dados biométricos pertencentes à mesma pessoa, enquanto que para pares pertencentes a pessoas diferentes o valor de $score$ tende a ser baixo.

Definidas as curvas de genuínos e impostores pode-se expressar as taxas FNMR e FMR através das equações 2.1 e 2.2 a seguir:

$$FNMR = \int_{-\infty}^{\beta} P(s / H_0) \quad (eq. 2.1)$$

$$FMR = \int_{\beta}^{\infty} P(s / H_1) \quad (eq. 2.2)$$

Onde β é o valor de limiar. A Figura 2.3 exibe os gráficos de FNMR e FMR para um dado valor de limiar.

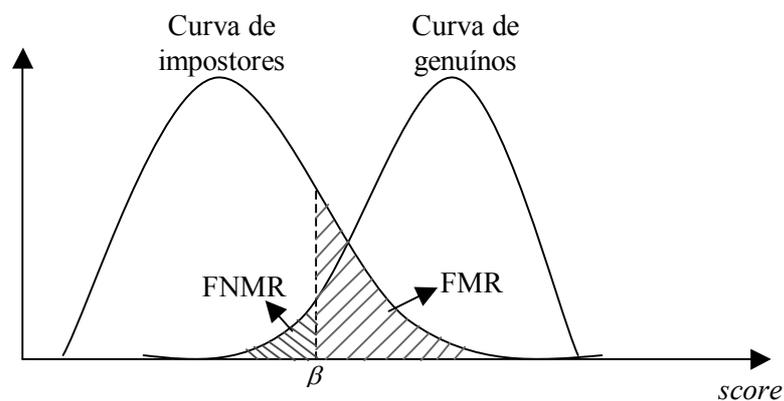


Figura 2.3 – Curva de genuínos e impostores. As áreas destacadas correspondem às regiões das taxas FNMR e FMR definidas pelo valor de limiar t .

Outro recurso muito utilizado para a determinação do valor de limiar é a curva ROC (*Receiver Operating Characteristic*), que consiste no gráfico da curva de FMR contra a curva FNMR ou $(1 - FNMR)$ para vários valores de β . A ROC pode ser obtida através da computação dos valores FRM e FNMR para vários valores de β . Desta forma é obtido um gráfico que exibe como essas duas grandezas se relacionam.

A ROC pode ser utilizada para se determinar qual a melhor relação FRM/FNMR para uma determinada aplicação, obtendo-se o valor limiar β que gera o par (FRM, FNMR) desejado. A Figura 2.4 exibe um exemplo de curva ROC.

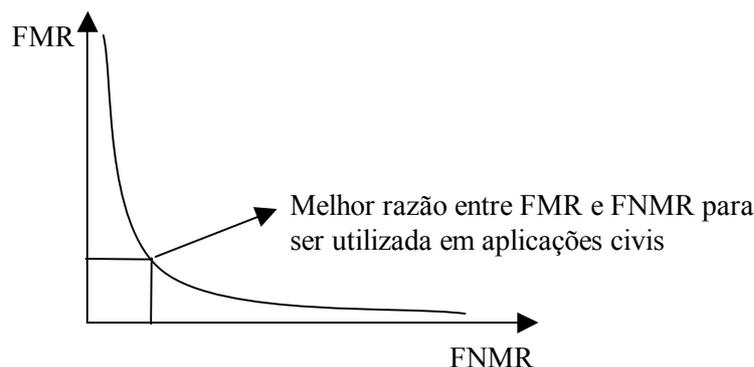


Figura 2.4 – Curva ROC. Esta curva exhibe a relação entre as taxas FMR e FNMR, auxiliando na determinação do valor de limiar.

Os processos de captura e cadastro dos dados biométricos também influenciam na precisão de um sistema biométrico.

Para que o processo de captura seja eficiente é necessário que o dispositivo utilizado seja capaz de detectar se há ou não um dado biométrico sendo apresentado a ele. Para tornar mais claro o que foi dito considere o seguinte exemplo:

- suponha que uma empresa deseja restringir o acesso a uma determinada sala de seu prédio somente a um grupo de funcionários, e decide utilizar um sistema de controle de acesso baseado em impressões digitais. Para tornar o sistema de fácil utilização, o funcionário não precisa se identificar, basta posicionar o dedo em um scanner e, automaticamente o sistema identifica o funcionário e libera ou não o acesso.

Neste exemplo o funcionário não precisa se identificar nem expressar a sua intenção de entrar na sala, a sua única ação é posicionar o dedo sobre o scanner, o que implica que este dispositivo deve, constantemente, capturar várias imagens em um pequeno intervalo de tempo e reagir somente quando nestas imagens houver uma impressão digital. Esta capacidade do dispositivo de captura de detectar a presença do dado biométrico é geralmente feita através de um software embutido no próprio dispositivo. Contudo, este software pode falhar na detecção da informação, basicamente pelos seguintes motivos:

- **Má qualidade do dispositivo:** o dispositivo é de baixa qualidade gerando uma informação ruidosa que dificulta na detecção correta da presença de um dado biométrico;

- **Má qualidade da característica biométrica:** o software de detecção pode não conseguir identificar o dado biométrico devido à má qualidade da própria característica biométrica, por exemplo, uma digital de alguém que tenha determinados problemas de pele;

- **Má interação entre usuário e dispositivo:** geralmente os dispositivos de captura possuem um manual com normas que o usuário deve seguir para que a captura seja bem sucedida. Por exemplo, para que um scanner detecte a impressão digital é necessário que o usuário não apenas coloque o dedo no dispositivo, mas que faça uma leve pressão contra o scanner para tornar as linhas, que formam a impressão digital, visíveis. Porém, se o usuário fizer pressão demais as linhas vão colar uma nas outras, pois a pele é elástica, criando um borrão.

Portanto, fica claro que um sistema biométrico está sujeito a erros durante o processo de captura. O percentual de erros de captura durante os processos de cadastro ou de uso do sistema será denotado por FTC (*Failure To Capture*). A FTC ajuda a medir a qualidade de um sistema biométrico, pois uma FTC muito alta pode indicar que o sistema não é confiável, pois podem ser necessárias várias capturas. Por outro lado, uma FTC muito baixa pode implicar um processo de captura muito complexo, desestimulando o interesse de pessoas em se tornarem usuários do sistema.

Para que o cadastro de um dado biométrico na base de padrões seja efetuado é necessário que não somente a captura do dado seja bem sucedida, mas que também a qualidade da captura seja garantida (Figura 2.1). O controle de qualidade é importante porque é desejável que na base de padrões estejam somente dados biométricos de boa qualidade, pois do contrário as taxas FMR e FNMR podem assumir valores acima do aceitável. No entanto, nem sempre as pessoas possuem qualidade suficiente em seus dados biométricos para passarem no controle de qualidade, indicando que aquela pessoa não pode utilizar aquele sistema biométrico sem detrimento das taxas FMR e FNMR. Por exemplo, uma pessoa que trabalha muito com água sanitária sem proteger as mãos, provavelmente não pode utilizar um sistema biométrico baseado em impressões digitais, ou uma pessoa que tem um problema grave em suas cordas vocais não pode utilizar um sistema baseado em identificação pela voz. A taxa de rejeições ocorridas durante o processo de controle de qualidade será denotada por FTE (*Failure To Enroll*).

Um sistema biométrico pode ser classificado como (JAIN, ROSS, PRABHAKAR, 2004):

- **unimodal**: quando o sistema biométrico utiliza apenas uma amostra de um tipo de dado biométrico;

- **multimodal**: quando o sistema utiliza múltiplas amostras de um mesmo tipo de dado biométrico, ou quando o sistema utiliza múltiplos dados biométricos de diferentes naturezas, como impressão digital e voz.

Os sistemas multimodais geralmente possuem FMR e FNMR mais baixas que sistemas unimodais, pois existem mais informações sobre os usuários. Se, além disso, o sistema multimodal utilizar tipos diferentes de dados biométricos, as taxas FTC e FTE podem ser mais baixas também, pois para aqueles usuários que não possuem qualidade suficiente em determinado tipo de dado biométrico podem ser utilizados apenas os outros tipos. Porém, os sistemas multimodais têm as desvantagens de serem mais caros, pois envolvem mais dispositivos de captura, e mais complicados de se utilizar.

Como visto nesta seção, os sistemas biométricos são sistemas de reconhecimento de padrões extraídos de características biológicas dos usuários do sistema. Durante a concepção do sistema devem ser levados em conta dados estatísticos (FMR, FNMR, FTC e FTE), o público alvo (os usuários do sistema) e o tipo de aplicação. Para que o estudo sobre sistemas biométricos fique mais completo, resta apenas conhecer melhor os tipos de biometrias mais utilizadas na atualidade, que é o tópico da próxima seção.

2.2 Tipos de Biometria

Como visto na seção anterior, um sistema biométrico pode utilizar uma ou mais características biométricas para fazer o reconhecimento de pessoas, uma vez que há um grande número de alternativas de dados biométricos que podem ser utilizados. Nesta seção são apresentadas, de forma breve, as principais biometrias utilizadas e pesquisadas, mostrando as suas principais aplicações e pesquisadores.

2.2.1 DNA

O pioneiro no campo da genética é Gregor Mendel que em 1865 descreveu em seu artigo (MENDEL, 1865), os seus experimentos com plantas, que comprovam o fato de as características dos pais serem passadas aos filhos. Em 1953, James Watson e Francis Crick descrevem, em um artigo para a revista Nature, a estrutura do DNA.

O ácido desoxirribonucléico (DNA) compõe a estrutura da vida, e em sua estrutura de forma helicoidal ele possui toda a informação necessária para criar um ser vivo. Através do DNA de uma pessoa é possível saber qual a cor de seus olhos, se ela tem tendência a adquirir determinadas doenças, qual a sua altura média na idade adulta e outras informações.

O DNA é único por pessoa (por ser vivo) exceto para irmãos univitelinos, que possuem DNA idêntico. No entanto, o processo de coleta de DNA ainda é complicado e extremamente dependente das habilidades de peritos, o que impede a sua utilização em aplicações de certificação em tempo real. Além disso, é muito fácil roubar um fragmento de DNA de uma pessoa e fraudar um sistema. Outra desvantagem com relação ao DNA é a questão ética envolvida, pois ter acesso às informações contidas no DNA é assunto de controvérsia, pois alguém poderia saber a quais doenças uma pessoa é susceptível, podendo causar discriminação, por exemplo, em uma entrevista de emprego.

Contudo, o DNA é um dado biométrico muito importante e o seu uso em criminalística é intenso já que é comum o criminoso deixar na cena do crime evidências como fios de cabelos, amostras de sangue, pele, saliva e outras secreções ou partes do corpo que possuem DNA.

A comparação de seqüências de DNA é feita através de um método de comparação de cadeias. Porém, como mencionado na Seção 2.1, o dado biométrico coletado possui ruídos inseridos tanto pelo processo de coleta como por meios externos, o que causa deformidades nas cadeias de DNA. Portanto, é necessário utilizar um método de comparação aproximada de cadeias, como o descrito em (NAVARRO, 2001).

2.2.2 Voz

A voz é uma combinação de características fisiológicas e comportamentais. As características do som produzido por uma pessoa são baseadas na forma e no tamanho de suas cordas vocais, boca, cavidades nasais e lábios. Essas características fisiológicas da fala humana não mudam com o tempo, porém as características comportamentais variam de acordo com a idade, estado de saúde, humor e outros.

Como a voz não possui um grau de distinção muito alto, o seu uso não é aconselhável em sistemas de identificação de larga escala. Um sistema de reconhecimento através da voz pode ser classificado como dependente de texto, onde o locutor é identificado através da sua pronúncia de um texto pré-estipulado, ou independente de texto, onde o locutor é identificado pelo que fala independente de um texto pré-concebido, consistindo em um sistema mais complexo, porém, mais seguro. Outra desvantagem está no fato de que as características da fala estão sujeitas a fatores externos como o som ambiente.

No entanto, a voz é usada para resolução de crimes, identificando um criminoso através de sua voz gravada em uma fita cassete, por exemplo. A voz é também adequada para a identificação de locutor em aplicações baseadas em telefonia, apesar do grande desafio de superar a degradação na qualidade da transmissão através do sistema telefônico.

Em (MAES, NAVRÁTIL, CHAUDHARI, 2001) é estudado um método que combina técnicas de reconhecimento de voz dependentes de texto com métodos independentes de texto, para se identificar o locutor em aplicações de comércio eletrônico.

Em (DINIZ, 1997) é desenvolvido um sistema baseado em redes neurais artificiais, capaz de reconhecer comandos de voz independente do locutor. Os comandos utilizados são aqueles geralmente utilizados para a manipulação de um aparelho de vídeo cassete.

2.2.3 Face

O desenho do rosto de alguém é com certeza a informação que as pessoas mais utilizam para se reconhecerem. Porém, este processo, que é feito de forma tão simples pelo cérebro, apresenta grandes desafios quando se tenta desenvolver uma abordagem computacional para o problema de identificação por face.

Uma das características que não se modificam no rosto de uma pessoa são as posições relativas entre determinados elementos que compõe um rosto, como os olhos, a boca e o nariz. A Figura 2.5(a) exibe um rosto e na Figura 2.5(b) as partes que compõe o rosto.



Figura 2.5 – O rosto de uma pessoa (a) e a localização dos olhos, boca e nariz (b).

Um conjunto de características muito usado para identificação de pessoas são as distâncias relativas entre os olhos, entre a boca e o nariz, entre os olhos e a boca e entre os olhos e o nariz. Portanto, o processo de identificação por face já exibe uma dificuldade que é a de localizar de forma precisa as posições dessas componentes do rosto. No caso da foto da Figura 2.5(a) pode ser que não haja grandes dificuldades para a localização dos elementos, pois só existe uma pessoa na foto e a pessoa está olhando para a direção da câmera, o que é uma foto típica de aplicações como controle de acesso onde o usuário é solicitado a olhar fixamente para câmera fotográfica. Porém, existem certas aplicações em que os usuários não sabem ou não precisam saber que estão sendo monitorados, por exemplo, a identificação de suspeitos de crimes em locais públicos como ruas, praças ou torcidas de um jogo de futebol. Nestes casos o problema é muito maior, pois é necessário localizar um rosto que pode estar em qualquer ângulo e distância com relação à câmera, e estar inserido em um fundo qualquer.

Portanto, antes da identificação do rosto é necessário resolver o problema de identificar em uma imagem as regiões que têm a possibilidade de ter um rosto. Em

(DASS, JAIN, LU, 2002) é utilizado um método baseado em modelos de Markov para identificar se uma imagem possui ou não uma face. Em (ROWLEY, BALUJA, KANADE, 1998; MOUTINHO, THOMÉ, BIONDI, MEZA, 2004) são propostos métodos baseados em redes neurais para a identificação de rostos dentro de uma imagem. A Figura 2.6 exibe um resultado deste trabalho, as regiões que foram identificadas como sendo um rosto estão envolvidas por um retângulo.

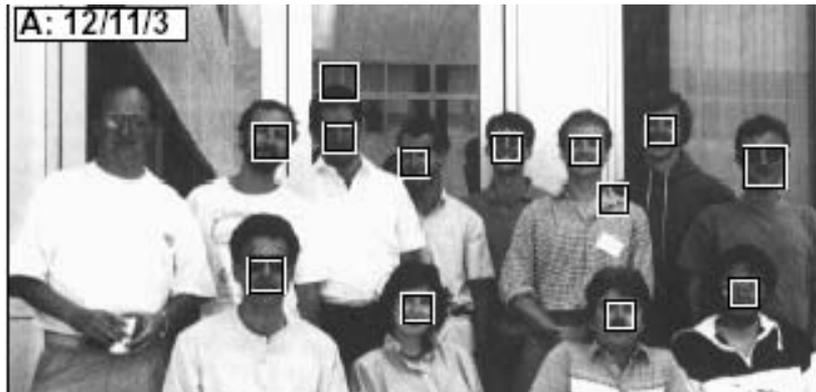


Figura 2.6 – Os resultados do localizador de faces proposto em (ROWLEY, BALUJA, KANADE, 1998). As regiões identificadas como faces estão envolvidas por um retângulo.

2.2.4 Íris

A íris é uma característica fisiológica que começa a ser formada no terceiro mês de gestação (KRONFELD, 1962), e as suas estruturas estão quase completamente formadas no oitavo mês. Os seus padrões complexos contêm muitas características discriminadoras tais como arcos, vales, linhas anéis e outros (DAUGMAN, 2004). A Figura 2.7 exibe um olho humano e sua íris.

Por se localizar no olho, a íris está bem protegida do meio ambiente e seus padrões não se modificam com o tempo. A quantidade destes padrões é muito alta e eles são formados por um processo aleatório enquanto a pessoa está se formando durante o processo de gravidez, o que garante aos sistemas baseados em íris uma taxa de falsa positividade de praticamente zero.

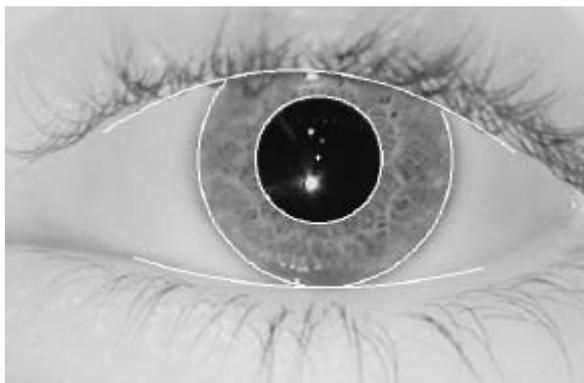


Figura 2.7 – Um olho humano visto a uma distância aproximada de 35 cm. As linhas brancas demarcam as bordas das pálpebras, íris e pupila.

Para que o reconhecimento de íris seja bem sucedido é necessário uma imagem com uma resolução mínima tal que o raio da íris tenha 70 pixels, apesar de que atualmente é mais típico o uso de imagens com raio variando entre 100 a 140 pixels. Geralmente se utilizam câmeras de CCD monocromáticas com iluminação variando entre 700nm a 900nm, para que a luz seja invisível ao olho humano. Além disso, é necessário detectar corretamente a posição do olho dentro da imagem, porém esta parte não é difícil já que o uso da íris é mais adequado para sistemas de certificação (como controle de acesso), onde a coleta do dado biométrico é controlada. Em (DAUGMAN, 2004) é descrito em detalhes os problemas, as vantagens e os métodos tanto de extração de características como de comparação de íris.

A íris quase não é utilizada em criminalística, pois dificilmente um criminoso deixará na cena de crime a imagem, com qualidade suficiente, de sua íris. Porém, como mencionado, para sistemas de certificação o seu uso é muito recomendado.

2.2.5 Dentes

Identificar pessoas mortas através de seus registros dentários é utilizado na área forense. Apesar dos dentes mudarem de forma com o tempo e das informações dentárias serem menos confiáveis do que outras características biométricas, muitas vezes elas são as únicas evidências que restam de uma vítima de acidente ou crime, por exemplo, em um incêndio praticamente só os ossos resistem, todas as outras características biológicas, como as impressões digitais, são destruídas.

Em (JAIN, CHEN, MINUT, 2003) é proposto um método de comparação de dentes a partir de imagens de radiografias. O objetivo é comparar a imagem dos dentes da vítima com as imagens de uma base composta pelos registros dentários de várias pessoas a fim de identificá-la. A Figura 2.8(a) exibe a radiografia de uma pessoa após a sua morte e a Figura 2(b) a radiografia tirada quando ainda em vida.

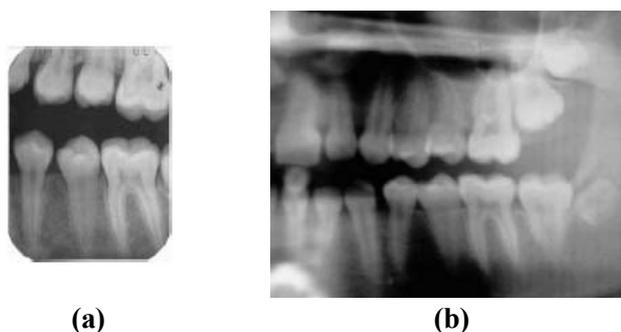


Figura 2.8 – Radiografia dos dentes de uma vítima (a) e sua radiografia tirada enquanto ainda estava viva (b).

A idéia principal do método proposto em (JAIN, CHEN, MINUT, 2003) é extrair, além da informação das posições relativas entre os dentes, informações da forma do contorno de cada dente, o que não é uma tarefa fácil, pois as imagens de radiografia possuem baixo contraste dificultando a detecção de bordas. Para diminuir a dificuldade desta tarefa os autores decidiram utilizar um método de detecção semi-automático, onde o usuário delimita, com um retângulo, a região onde se encontra o dente e marca com um ponto a posição da coroa, a Figura 2.9 exibe este procedimento.



Figura 2.9 – Imagem de um dente onde o usuário demarcou sua posição através de um retângulo, e marcou a posição da coroa com um ponto.

Depois é detectado o contorno do dente através dos gradientes da imagem. A Figura 2.10 exibe o contorno extraído do dente da imagem da Figura 2.9.



Figura 2.10 – Contorno extraído do dente da Figura 2.9.

Após a extração do contorno são extraídas informações relativas à forma da coroa e da raiz do dente, que depois é usado para comparar contra a base de padrões. O trabalho apresenta resultados promissores apesar de ter problemas com imagens muito borradas.

2.2.6 Geometria das mãos

As mãos possuem características como largura dos dedos em várias posições, largura e espessura da palma, tamanho dos dedos e outras, que podem ser utilizadas como um dado biométrico.

As vantagens de se utilizar as palmas das mãos em um sistema biométrico são a sua fácil coleta, possuem um conjunto de características de fácil manipulação computacional, não exigem informações particulares do usuário como impressões digitais ou imagem da íris, e as suas características não se modificam de forma significativa ao longo do tempo.

A grande desvantagem, no entanto, está no fato de seu baixo poder de discriminação, o que torna o seu uso mais adequado para aplicações de certificação do que identificação.

Em (JAIN, PANKANTI, ROSS, 1999) é proposto o modelo de um sistema de certificação baseado na geometria das mãos. O método usa imagens obtidas com um aparelho de captura que possui uma lâmpada, uma câmera, pinos que indicam como o usuário deve posicionar sua mão, e um espelho que permite a captura da imagem da lateral da mão. A Figura 2.11 exibe uma pessoa utilizando o aparelho.



Figura 2.11 – Aparelho de captura da imagem da mão. Os pinos indicam como a pessoa deve usar o aparelho. O Espelho, à esquerda da imagem, permite que a câmera capture a imagem da lateral da mão.

Os resultados obtidos foram apresentados através da curva ROC, como exibido na Figura 2.12.

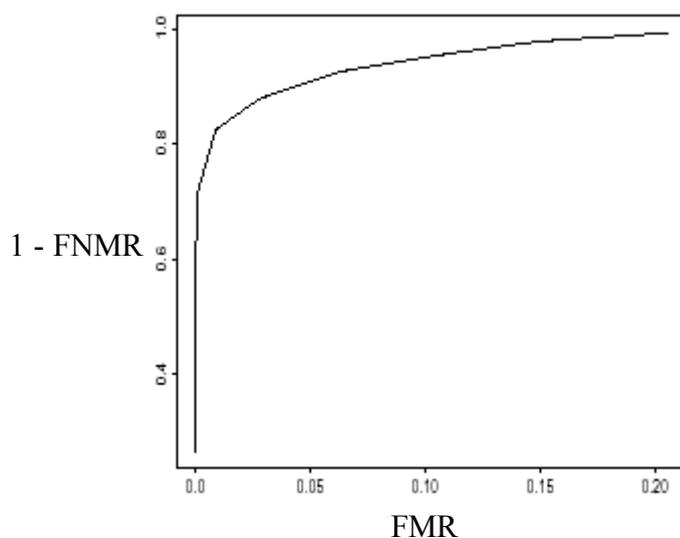


Figura 2.12 – Curva ROC obtida pelo método apresentado em (JAIN, PANKANTI, ROSS, 1999). Esta curva apresenta a taxa de falsas positivamente (FMR) contra as taxas de verdadeiras positivamente (1 – FNMR).

2.2.7 Impressões Digitais

As Impressões digitais são formadas por linhas e sulcos presentes na pele das áreas de contato, como palma das mãos, planta dos pés e ponta dos dedos. A Figura 2.13 exibe uma impressão digital colhida com tinta sobre um pedaço de papel.



Figura 2.13 – Imagem de uma impressão digital colhida com tinta sobre um pedaço de papel.

Os padrões das linhas de uma impressão digital é único, sendo de 1 para $1,9 \times 10^{15}$ a probabilidade de duas impressões digitais serem iguais (NETO, 2000). Devido a essa baixa probabilidade o uso de impressões digitais em criminalística se dá desde o início do século XX.

Os peritos em impressões digitais comparam duas impressões utilizando características peculiares de seus desenhos, como a posição dos poros da pele (poroscopia) ou o desenho das linhas, conhecidas como linhas papilares (papiloscopia). As linhas papilares possuem pontos de descontinuidades, conhecidos por minúcias, que consistem em posições onde uma linha termina ou bifurca. O trabalho de um perito em papiloscopia consiste basicamente em localizar as minúcias, anotando a sua posição relativa dentro do desenho da impressão digital, a direção da linha onde foi encontrada a minúcia e o seu tipo, que indica se é uma minúcia de fim-de-linha ou uma bifurcação. A Figura 2.14 exibe uma minúcia de fim-de-linha e uma bifurcação.

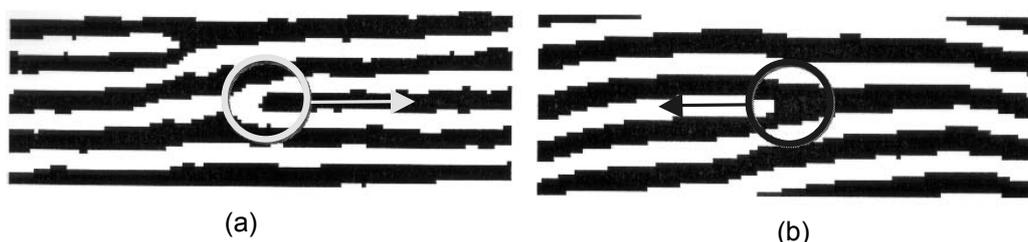


Fig. 2.14 – Tipos de minúcias. (a) fim-de-linha; (b) bifurcação.

Após o advento do computador o processo de localização de minúcias passou de manual para automático ou semi-automático, dependendo da aplicação.

Como mencionado na Seção 2.1, no momento da captura do dado biométrico, não é capturado somente a informação de interesse, mas outras informações irrelevantes são trazidas também pelo sensor ou coletor. Por exemplo, a imagem apresentada na Figura 2.13 é um fragmento de uma ficha de identificação civil, como a utilizada no momento em que o cidadão solicita a carteira de identidade. Esta imagem possui não somente a digital, mas outros elementos como marcadores de posição e anotações feitas pelos peritos que manipulam as fichas. A Figura 2.15 exhibe esses elementos presentes na imagem da Figura 2.13.

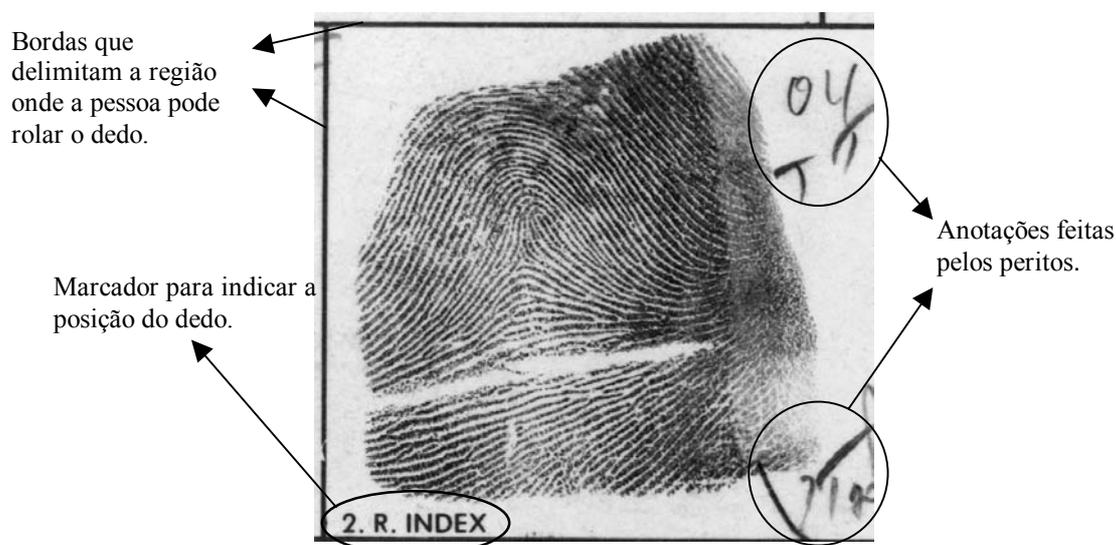


Figura 2.15 – Imagem da mesma impressão digital exibida na Figura 2.13. Observe os vários elementos que também se encontram na imagem e não fazem parte da digital.

Portanto, antes que as minúcias possam ser extraídas é necessário fazer a detecção das regiões da imagem que possuem impressão digital, da mesma forma que, antes de se fazer o reconhecimento de uma pessoa pelo rosto é necessário localizar os rostos presentes na imagem. Este problema consiste num dos focos desta pesquisa e é discutido mais detalhadamente no Capítulo 5.

As impressões digitais são utilizadas tanto em aplicações de identificação como de certificação, pois possuem a vantagem de não serem de difícil coleta, alto poder de discriminação e se modificam muito pouco ao longo da vida. Porém, como as impressões digitais se encontram nas mãos, elas não estão bem protegidas do meio ambiente, além disso, não é muito difícil conseguir uma cópia da digital de alguém e utilizá-la de forma fraudulenta.

Impressões digitais são o foco desta dissertação e, portanto, serão vistas mais profundamente no Capítulo 3, onde serão apresentados algoritmos de extração de minúcias, assim como no Capítulo 5 onde é discutido o problema da segmentação.

2.3 Considerações Finais

Como visto nas seções deste capítulo, existem vários tipos de biometria que podem ser utilizados em sistemas biométricos, dependendo da aplicação e do capital disponível. Os tipos biométricos apresentados não são os únicos, porém o objetivo principal é trazer ao leitor uma visão geral de biometria e não um estudo muito aprofundado. Outros dados biométricos que também são utilizados são a retina, o jeito da pessoa andar (*gait*), a impressão de orelha, odor, desenho das veias das mãos, gráfico térmico da face, assinatura e outros.

Apesar dos estudos biométricos datarem desde o século XIX, ainda há muito que ser estudado, tanto no aspecto tecnológico quanto na sua modelagem matemática. No futuro os estudos sobre o corpo humano podem revelar novas características biométricas que poderão ser exploradas, além disso, nada impede que uma característica biométrica não utilizada na atualidade possa vir a ser utilizada no futuro, seja por questões de avanços da tecnologia dos dispositivos de captura quanto na descoberta de novas propriedades que a tornem mais atraente.

A Tabela 2.1 exhibe um comparativo entre os tipos diferentes de biometria (JAIN, ROSS, PRABHAKAR, 2004).

Dado biométrico	Universalidade	Unicidade	Facilidade de Coleta	Imutabilidade	Performance	Aceitabilidade	Facilidade de Fraude
DNA	Alta	Alta	Baixa	Alta	Alta	Baixa	Baixa
Orelha	Média	Média	Baixa	Alta	Média	Alta	Média
Face	Alta	Baixa	Alta	Média	Baixa	Alta	Alta
Termograma Facial	Alta	Alta	Alta	Baixa	Média	Alta	Baixa
Impressão Digital	Média	Alta	Média	Alta	Alta	Média	Média
Jeito de Andar	Média	Baixa	Alta	Baixa	Baixa	Alta	Média
Geometria das mãos	Média	Média	Alta	Média	Média	Média	Média
Desenho das veias das mãos	Média	Média	Média	Média	Média	Média	Baixa
Íris	Alta	Alta	Média	Alta	Alta	Baixa	Baixa
Odor	Alta	Alta	Baixa	Alta	Baixa	Média	Baixa
Retina	Alta	Alta	Baixa	Média	Alta	Baixa	Baixa
Assinatura	Baixa	Baixa	Alta	Baixa	Baixa	Alta	Alta
Voz	Média	Baixa	Média	Baixa	Baixa	Alta	Alta

Tabela 2.1 – Comparação entre alguns tipos de dados biométricos (JAIN, ROSS, PRABHAKAR, 2004). Cada linha corresponde a um dado biométrico e cada coluna corresponde ao grau de sua propriedade, sendo classificado como alto, médio e baixo.

3 IMPRESSÕES DIGITAIS

No Capítulo 2 foram descritos alguns tipos de características biológicas utilizadas para identificação pessoal. Neste capítulo é dado ênfase ao estudo das impressões digitais, que são o foco principal deste trabalho.

Nas próximas seções serão vistos o processo de formação das impressões digitais, a sua individualidade, a sua utilização em criminalística e o uso de computadores no processo automático de identificação.

3.1 Formação e Características das Impressões Digitais

As impressões digitais são formadas por linhas e sulcos presentes nas palmas das mãos, planta dos pés e pontas dos dedos. Na natureza, a sua função principal é aumentar o atrito destas partes do corpo para facilitar a tarefa de segurar e agarrar objetos, no caso das mãos, e evitar que escorreguemos, no caso dos pés. A Figura 3.1 exibe a imagem de uma impressão digital que foi colhida com tinta sobre um pedaço de papel.



Figura 3.1 – Impressão digital de um polegar colhida sobre um pedaço de papel.

O processo de formação das impressões digitais se completa aproximadamente no sétimo mês de gravidez e as configurações das linhas não se alteram no decorrer da

vida da pessoa exceto por acidentes como cortes nos dedos (MALTONI, MAIO, JAIN, PRABHAKAR, 2003).

A aparência de qualquer característica corporal é determinada por fatores genéticos e ambientais. Por exemplo, irmãos gêmeos idênticos (univitelinos) possuem o mesmo DNA, porém, podem apresentar formações ósseas diferentes se tiverem recebido alimentos com diferentes concentrações de cálcio e vitamina D ou tiverem sido expostos ao sol por diferentes períodos.

Da mesma forma, o desenho geral das linhas de uma impressão digital é determinado geneticamente, porém, os detalhes finos das linhas são determinados pelas constantes mudanças do fluxo do fluido amniótico e da posição do feto no interior do útero da mãe, de onde se conclui que nem gêmeos univitelinos, mencionados no parágrafo anterior, possuem impressões digitais iguais. Detalhes do desenvolvimento das linhas da epiderme podem ser encontrados em (BABLER, 1991).

O estudo sobre impressões digitais ocorre há muito tempo. O inglês Nehemiah Grew publicou seu artigo científico em 1684 relatando seu estudo sistemático sobre as estruturas das linhas, sulcos e poros em impressões digitais. Em 1892, Sir Francis Galton conduziu um estudo metucioso sobre impressões digitais (GALTON, 1892). Assim como Galton, outros pesquisadores, como Edward Henry, perceberam que o desenho geral das linhas de uma impressão digital não é totalmente aleatório, mas apresentam padrões que ocorrem em quase todas as impressões digitais. A Figura 3.2 exibe uma formação comum nas linhas de uma impressão digital, que é chamada de ápice, onde as linhas parecem dar meia-volta.

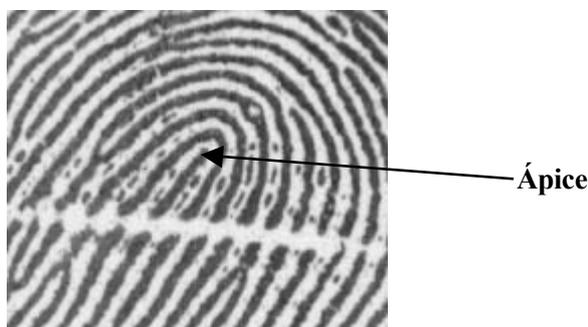


Figura 3.2 – Imagem de um ápice, que é um padrão no fluxo das linhas, onde as linhas parecem dar meia-volta.

A Figura 3.3 exibe um delta, outro padrão muito comum em impressões digitais. Neste padrão as linhas parecem formar um triângulo (delta).

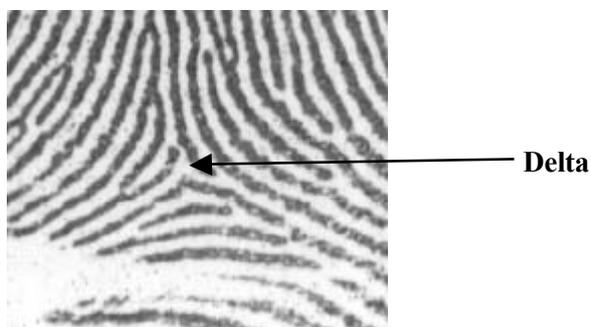


Figura 3.3 – Imagem de um delta, um padrão comum em impressões digitais, que é caracterizado pelo fato de parecer que o fluxo das linhas formam um triângulo.

A presença de ápices e deltas em uma impressão digital permitiu a elaboração de um esquema de classificação de impressões digitais. O esquema de classificação não é fixo, variando de acordo com o estudo de cada pesquisador. Os esquemas mais conhecidos são de Galton (GALTON, 1892) e Henry (HENRY, 1900). A quantidade de ápices e deltas que aparecem em uma impressão digital, com raras exceções, é no máximo dois, tanto para ápice como para delta. A seguir, é apresentado um esquema simplificado de classificação que leva em conta a quantidade e o posicionamento relativo dos ápices e deltas:

- **Arco**: é classificada como *Arco* uma impressão digital que não possui nem ápices e nem deltas;
- **Presilha Interna**: uma impressão digital que possui exatamente um delta posicionado à direita de apenas um ápice é classificada como *Presilha Interna*;
- **Presilha Externa**: a *Presilha Externa* se diferencia da *Presilha Interna* apenas pelo fato do delta se encontrar à esquerda do ápice;
- **Verticilo**: o *Verticilo* é caracterizado pela presença de dois ápices e dois deltas.

A Figura 3.4 exibe exemplos de cada uma das classes de impressões digitais apresentadas acima.

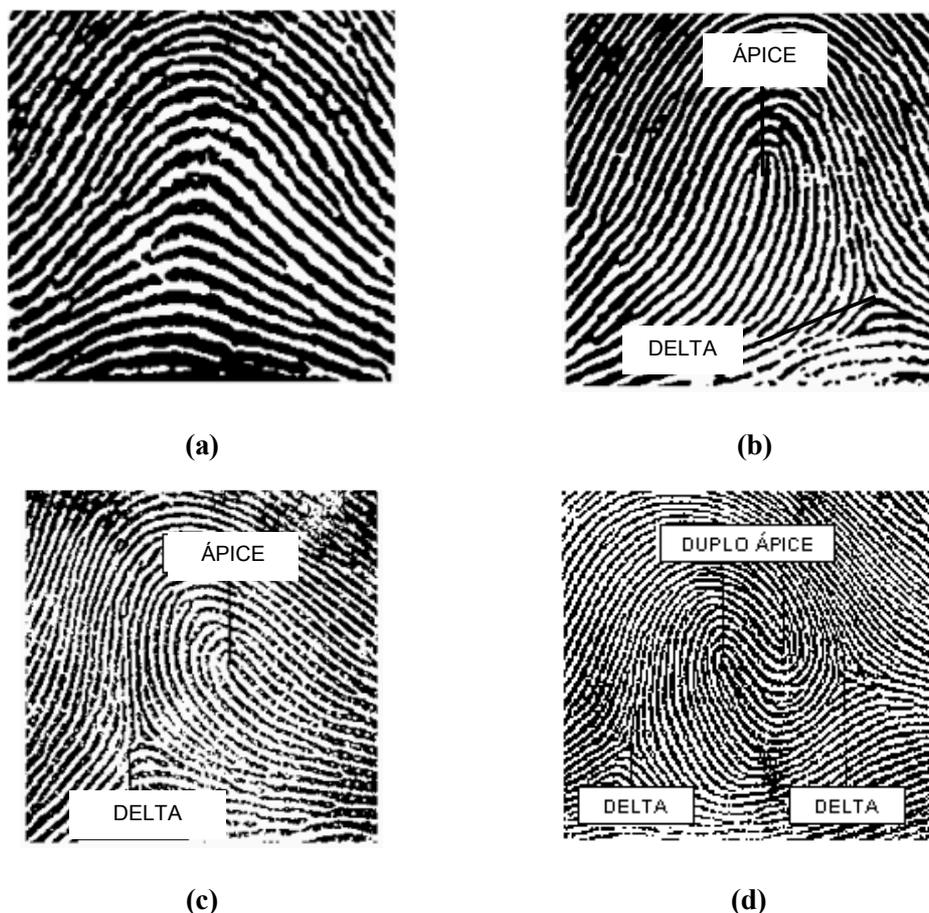


Figura 3.4 – Alguns tipos de classes utilizadas para classificar impressões digitais. (a) Arco, (b) Presilha Interna, (c) Presilha Externa e (d) Verticilo.

É interessante observar que os esquemas de classificação concebidos no final e no início dos séculos XIX e XX respectivamente, só são possíveis graças ao fato de que os desenhos das linhas não são formados por um processo completamente aleatório, o que é consistente com as descobertas genéticas relativamente recentes, de que o desenho geral das linhas é em grande parte determinado geneticamente, ou seja, não é aleatório.

Por isso, há uma alta correlação entre a classificação das impressões digitais de gêmeos idênticos, e esta correlação cai drasticamente conforme o grau de parentesco diminui. Contudo, ao se analisar detalhadamente as impressões digitais de gêmeos idênticos, muitas diferenças são encontradas, pois como visto no início desta seção, os detalhes finos das impressões digitais são determinados pela interação da epiderme com o ambiente conforme as impressões digitais se desenvolvem, e nem todos os fatores que contribuem neste processo de desenvolvimento são completamente conhecidos (BABLER, 1991). Portanto, como os detalhes de uma impressão digital são formados

por um processo aleatório, isso significa que é muito improvável que duas impressões digitais sejam iguais quando analisadas detalhadamente, mesmo para irmãos gêmeos idênticos.

O que falta estudar são justamente estas características individuais de uma impressão digital. Uma destas características são os poros presentes na impressão digital. O conjunto e as posições dos poros de uma impressão digital é único, ou seja, não existem duas impressões digitais com conjuntos de poros iguais. A Figura 3.5 exhibe uma impressão e seus poros. A Poroscopia é a ciência que estuda os poros.

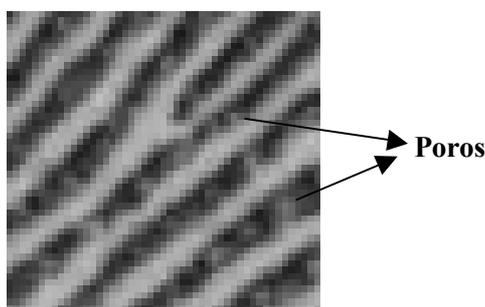


Figura 3.5 – Uma impressão digital com alguns poros.

Outra característica das impressões digitais são as minúcias, que consistem em pontos de descontinuidades das linhas que formam a impressão digital. As minúcias podem ser classificadas basicamente em dois tipos, que são descritos a seguir:

- fim-de-linha: ponto em que uma linha termina, Figura 3.6(a);
- bifurcação: ponto em que uma linha se divide em duas, Figura 3.6(b).

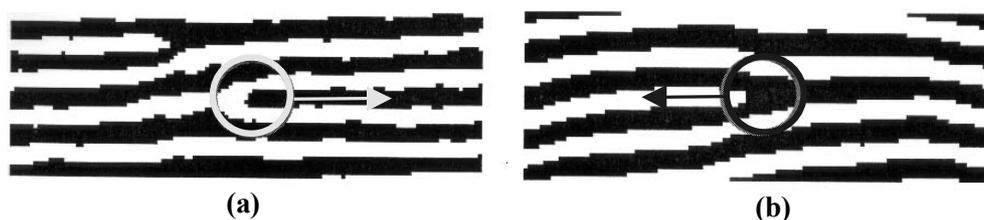


Figura 3.6 – Tipos de minúcias, fim-de-linha (a) e bifurcação (b). As setas indicam a direção das linhas.

Cada minúcia possui 3 informações, que são, as suas coordenadas vertical e horizontal que a localizam dentro da impressão digital, a direção da linha a qual ela pertence e o seu tipo (bifurcação ou fim-de-linha). Na literatura existem outros tipos de

minúcias, porém, por simplificação, todos os outros tipos podem ser obtidos pela conjunção de um ou mais fins-de-linha e bifurcações.

O conjunto de minúcias de uma impressão digital é único, ou seja, não existem duas impressões digitais com o conjunto de minúcias iguais. As minúcias são as características mais utilizadas pela perícia na solução de crimes desde o início do século XX, apesar dos peritos também utilizarem outros tipos de informações ao compararem impressões digitais.

Em criminalística as impressões digitais desempenham um papel importante, pois os criminosos podem deixar as suas impressões digitais na cena do crime. As impressões são deixadas através do suor e da gordura presente na pele que se aderem a superfícies geralmente lisas como o vidro. As impressões digitais encontradas em cenas de crime são chamadas de impressões latentes, pois geralmente não são visíveis para olhos não treinados. A Figura 3.7 exibe a imagem de uma impressão latente, observe que a qualidade da impressão digital obtida é bem baixa, ou seja, não há muitas minúcias ou outros pontos característicos disponíveis.



Figura 3.7 – Imagem de uma impressão digital latente encontrada na cena de um crime. Observe a baixa quantidade disponível de minúcias ou poros.

3.2 Extração Automática de Minúcias

Após o surgimento dos computadores, as impressões digitais passaram a ser utilizadas em aplicações civis de segurança, como controle de acesso por exemplo. Para que o seu uso em computadores pudesse ser automatizado foi necessário a criação de métodos automáticos de extração de características e de comparação destas características.

São chamados de codificadores os métodos e algoritmos de extração de características de impressões digitais. Um codificador deve receber a imagem de uma impressão digital e gerar como saída uma estrutura de dados contendo as características extraídas da imagem da impressão digital. Geralmente um codificador segue as seguintes fases:

- **Pré-processamento:** nesta fase são aplicados filtros sobre a imagem, com o objetivo de realçar a sua qualidade ou alguma característica;
- **Segmentação ou Detecção da Região de Interesse:** esta fase é responsável pela detecção da região da imagem que possui a impressão digital separando-a das demais regiões da imagem. Esta fase será vista no Capítulo 5;
- **Extração de Características:** nesta fase ocorre a extração das características que serão utilizadas na comparação das impressões digitais. As características a serem extraídas podem ser as minúcias, as posições dos poros, ou outra característica ou ainda, uma combinação delas;
- **Pós-Processamento:** esta fase tem como objetivo refinar o resultado obtido da fase anterior, removendo eventuais características espúrias.

Um sistema automático de identificação de impressões digitais, cuja sigla em inglês é AFIS (Automated Fingerprint Identification System), utiliza um módulo extrator (codificador) e uma base de dados para armazenar as características extraídas das impressões digitais de cada indivíduo cadastrado no banco. A base de dados será utilizada futuramente para descobrir ou certificar a identidade de alguém.

O AFIS implantado nos Estados Unidos da América é o exemplo mais clássico de um sistema deste tipo. O AFIS norte-americano consiste em um sistema criminal

utilizado, principalmente pelo FBI, para resolução de crimes, ou seja, o sistema não é utilizado para identificação civil.

A extração correta das características é vital para o funcionamento eficiente de qualquer sistema baseado em impressões digitais. Por isso, vários pesquisadores têm estudado este problema e proposto vários métodos e algoritmos para resolvê-lo. As características extraídas das impressões digitais geralmente são as minúcias, pois o seu estudo científico é muito aprofundado e antigo.

A extração correta das minúcias depende da qualidade da imagem coletada. Em sistemas de controle de acesso, por exemplo, o usuário é solicitado a colocar sua impressão digital sobre um *scanner* para que a imagem extraída possa ser utilizada para conceder ou não o seu acesso a um determinado local. Neste caso, o usuário é cooperativo, a coleta é controlada e a qualidade do *scanner* pode ser previamente determinada. Porém, em alguns casos a qualidade da coleta pode não ser garantida, por exemplo, se a pele da pessoa for muito ressecada, muitas estrias podem surgir durante a coleta, não garantido uma boa qualidade.

Portanto, a extração de minúcias em imagens de qualidade média ou ruim é um problema difícil e intensivamente estudado, porém ainda sem uma solução definitiva (MALTONI, MAIO, 1998).

Os métodos de extração basicamente se dividem em 2 grupos, os métodos baseados na abordagem clássica, que consiste em binarizar a imagem e extrair as minúcias da imagem em preto e branco, e os métodos baseados na extração direto em tons de cinza. Nas próximas seções serão vistos alguns algoritmos de extração baseados em ambas abordagens.

3.2.1 Método Clássico

A extração clássica de minúcias consiste, basicamente, em binarizar a imagem convertendo-a de tons de cinza para preto e branco, aplicar um afinamento nas linhas e detectar os pontos onde as linhas terminam ou bifurcam. A Figura 3.8 exibe um fragmento de impressão digital antes e depois do processo de binarização.

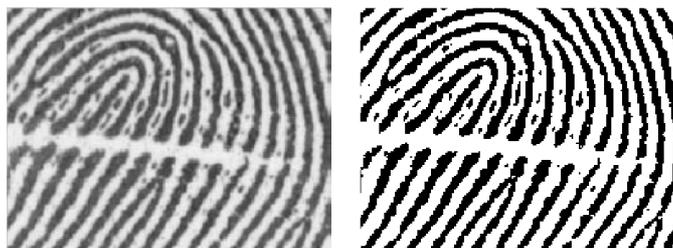


Figura 3.8 – Imagem de um fragmento de impressão digital (esquerda) e o resultado obtido após o processo de binarização (direita).

A Figura 3.9 exibe o mesmo fragmento da Figura 3.8 após o processo de afinamento das linhas.



Figura 3.9 – (a) Fragmento binarizado de uma impressão digital. (b) Resultado do processo de afinamento aplicado em (a).

O processo de afinamento (GONZALEZ, WOODS, 2000) garante que as linhas possuem exatamente um pixel de largura, por isso, a busca pelos fins-de-linha e bifurcações é relativamente simples, pois basta varrer a imagem em busca de pixels pretos que tenham exatamente um vizinho preto (fim-de-linha) ou que tenham exatamente 3 vizinhos pretos (bifurcação).

Apesar de simples, a abordagem clássica possui algumas desvantagens, por exemplo:

- o processo de binarização provoca perda de informação;
- se a imagem possuir uma qualidade ruim, a binarização irá criar muitas minúcias espúrias, ou seja, o processo é muito dependente da qualidade da imagem e de um bom pré-processamento.

Vários pesquisadores propuseram algoritmos clássicos propondo variações nos processos de binarização, pré-processamento e pós-processamento. Em (LEUNG, LEUNG, LAU, LUK, 1991) é proposto um algoritmo, baseado na abordagem clássica,

em que a detecção das minúcias após o afinamento é feita utilizando-se uma rede neural treinada com padrões de fins-de-linha e bifurcações. Em (NETO, 2000) é implementado um algoritmo clássico em que as minúcias espúrias são removidas utilizando-se um critério de remover minúcias muito próximas de forma hierárquica, primeiro removendo as minúcias com distância menor ou igual a 7 pixels e depois a 14 pixels.

A abordagem clássica geralmente funciona bem para imagens de boa qualidade, mas quando isso não ocorre, várias minúcias espúrias são geradas. Principalmente por este motivo outros algoritmos têm sido propostos.

A Figura 3.10 exibe um exemplo de uma imagem de boa qualidade. Observe que as linhas da impressão digital estão bem definidas e em bom contraste com o fundo.



Figura 3.10 – Imagem de uma impressão digital de boa qualidade. Observe que as linhas, além de estarem bem definidas (pouco falhadas), possuem um bom contraste com o fundo.

A Figura 3.11 exibe uma impressão digital de baixa qualidade. Observe que as linhas estão muito falhadas e o contraste com o fundo é baixo.

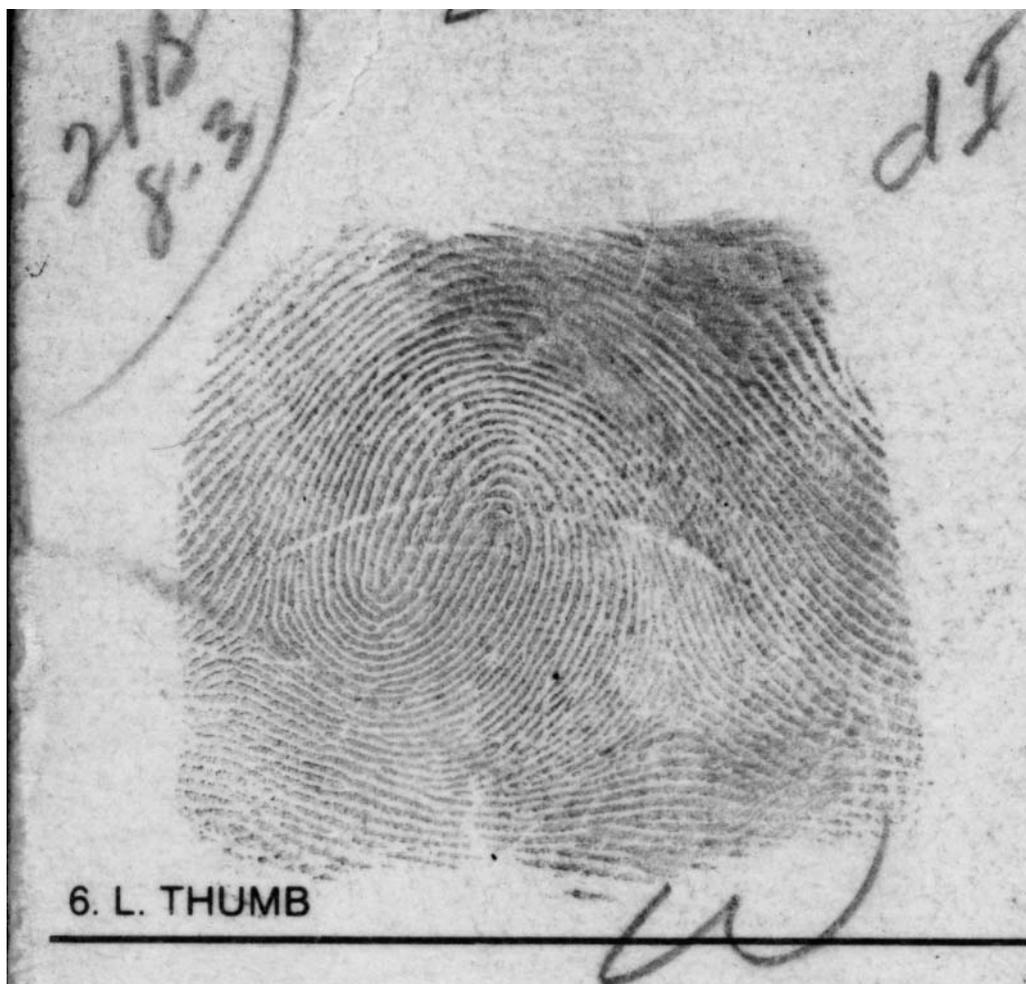


Figura 3.11 – Imagem de uma impressão digital de baixa qualidade. Observe que as linhas estão falhadas e possuem um baixo contraste com o fundo.

3.2.2 Métodos Não Clássicos

Como visto na seção anterior, a detecção de minúcias em imagens de média ou baixa qualidade exige que outros métodos, diferentes da abordagem clássica, sejam elaborados.

Em (MALTONI, MAIO, 1997) é proposto um método de extração de minúcias em que as linhas da impressão digital são detectadas diretamente em tons cinza, baseando-se no fato de que as linhas são máximos locais se for considerado que os tons

de cinza de uma imagem representam alturas, de forma que, quanto mais escuro um ponto da imagem mais alto ele se encontra. Note que esta não é a convenção mais adotada, geralmente os tons de cinza mais escuros estão associados às alturas mais baixas. A Figura 3.12 exemplifica como as linhas de uma impressão digital são vistas quando se utiliza os tons de cinza como alturas.

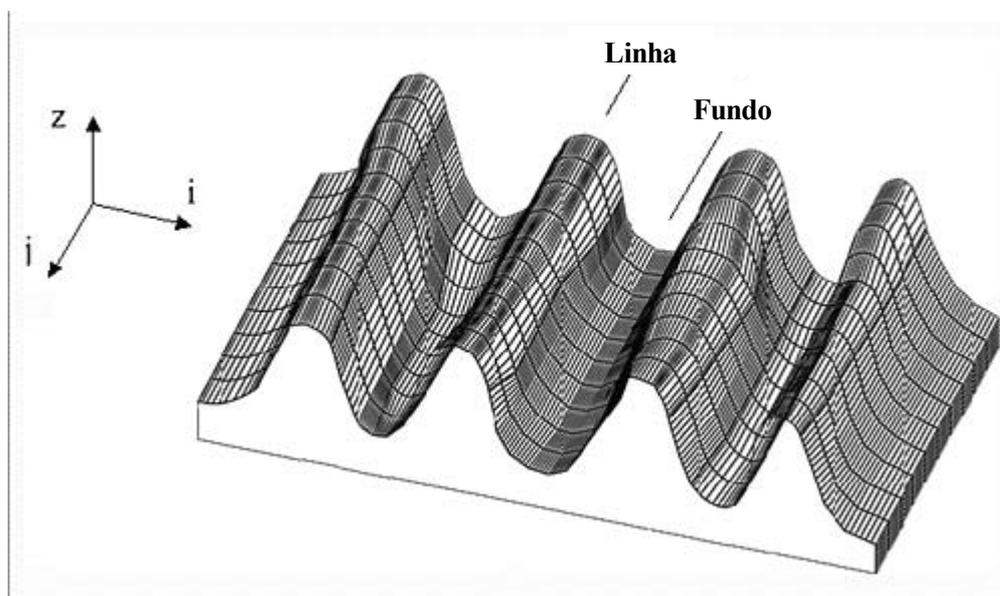


Figura 3.12 – Linhas de uma impressão digital vistas como um sólido tridimensional, onde o tom de cinza da imagem representa a altura da superfície. Os eixos z , j e i representam respectivamente o tom de cinza da imagem, a direção das linhas e a direção ortogonal às linhas. As linhas representam máximos locais ao longo do eixo i .

Após a detecção de uma linha, esta é percorrida com um passo fixo μ , até um ponto onde ela termina ou bifurca, detectando-se assim, um fim-de-linha ou uma bifurcação respectivamente.

Os mesmos autores propuseram um método de pós-processamento, baseado em redes neurais, para eliminar e corrigir minúcias espúrias geradas pelo método proposto (MALTONI, MAIO, 1998).

Em (JIANG, YAU, SER, 2001) é proposta uma variação no método descrito acima. Ao invés de usar um passo μ fixo para percorrer a linha, ele é adaptado dinamicamente de acordo com as mudanças de contraste e de curvatura das linhas. O passo μ diminui conforme a curvatura da linha aumenta.

Em (LIU, HUANG, CHAN, 2000) é também proposta uma outra modificação no mesmo algoritmo. Os autores propõem que ao invés de se percorrer apenas as linhas, devem também ser percorridos os vales adjacentes à linha. Como os vales representam mínimos locais (o contrário das linhas), a cada passo do algoritmo existe uma tripla $\langle \text{mínimo}, \text{máximo}, \text{mínimo} \rangle$. O ponto em que esta tripla se inverte para $\langle \text{máximo}, \text{mínimo}, \text{máximo} \rangle$ significa que há uma minúcia neste local.

Em (LEUNG, ENGELER, FRANK, 1990) as minúcias são detectadas utilizando-se um banco de filtros de Gabor Complexo. O filtro de Gabor Complexo é um filtro linear sensível a mudanças de fases nas senóides que compõem a imagem. Este filtro será melhor descrito no Capítulo 4. A imagem é filtrada utilizando-se 6 filtros de Gabor, um para cada direção, depois são utilizadas 6 redes neurais que recebem como entrada cada uma, a saída de um filtro específico, ou seja, cada rede é treinada para detectar minúcias em uma direção específica. Depois é utilizado um classificador para combinar as saídas das redes.

(SAGAR, NGO, FOO, 1995) propõem o uso de lógica nebulosa para detecção das minúcias utilizando uma analogia interessante, comparando a imagem binária do método tradicional com um conjunto tradicional (crisp), e a imagem em tons de cinza com um conjunto nebuloso. Na abordagem clássica, a binarização é utilizada para classificar cada ponto como pertencente ao fundo ou a uma linha da impressão digital, mas em (SAGAR, NGO, FOO, 1995) são utilizados dois conjuntos nebulosos, o conjunto *Escuro* e o *Claro*. O tom de cinza de um ponto na imagem original é utilizado para inferir os graus de pertinência deste ponto nos dois conjuntos. A Figura 3.13 ilustra os conjuntos nebulosos *Escuro* e *Claro*.

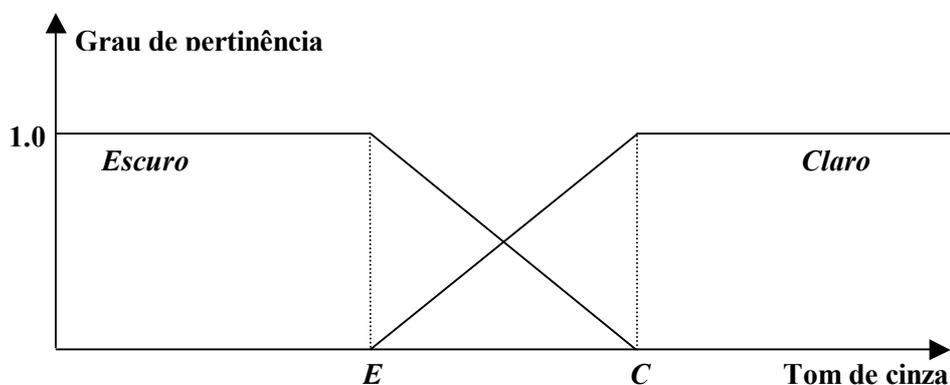


Figura 3.13 – Conjuntos nebulosos que definem se uma região é clara ou escura de acordo com o nível de cinza.

Observe na Figura 3.13, que quanto maior for o nível de cinza mais claro ele é considerado, ao contrário da convenção adotada em (MALTONI, MAIO, 1997). Os limites *C* e *E* da figura são determinados dinamicamente de acordo com a região da imagem que estiver sendo analisada, adaptando-se ao nível de contraste local.

O método de extração final se dá da seguinte forma: para cada ponto da imagem são extraídas a média de tons de cinza de 8 janelas localizadas ao redor do ponto corrente. Depois, cada valor de média é nebulizado utilizando-se os conjuntos *Escuro* e *Claro*, gerando 16 graus de inclusão, que correspondem ao grau de inclusão de cada uma das 8 médias em cada um dos dois conjuntos. Finalmente, um conjunto de regras nebulosas utiliza estes 16 graus de inclusão para determinar se naquele ponto existe ou não uma minúcia. A Figura 3.14 ilustra as 8 janelas mencionadas.

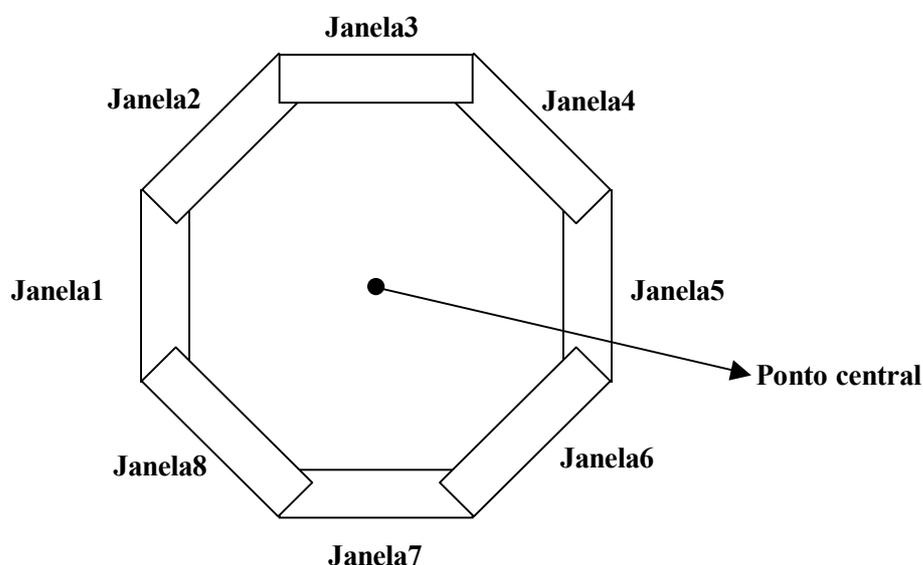


Figura 3.14 – Janelas utilizadas pelo sistema de regras nebuloso proposto em (SAGAR, NGO, FOO, 1995) para determinar a presença de uma minúcia.

Em (SAGAR, BENG, 1999) é proposta uma mudança no sistema nebuloso descrito anteriormente. São utilizados 4 conjuntos de 8 janelas ao invés de um único conjunto, perfazendo um total de 32 janelas ao invés de 8. Cada conjunto de janelas está a uma distância diferente do pixel central. Como o número de janelas é quatro vezes maior, o número de regras nebulosas seria muito grande, por isso, os autores propõem o uso de duas redes neurais que recebem como entrada os graus de pertinência da média de cada uma das 32 janelas, e classificam o ponto como sendo uma bifurcação, um fim-

de-linha ou não-minúcia. Duas redes são utilizadas, uma treinada para detecção de fim-de-linha e a outra para bifurcações.

Apesar de outros métodos de extração de minúcias terem sido propostos, os mencionados nesta seção exemplificam bem como abordagens bem diferentes foram adotadas para resolver o mesmo problema, evidenciando a sua dificuldade.

A existência de vários métodos extratores de minúcias traz um problema no que diz respeito à troca de informações entre sistemas automáticos de impressões digitais. Suponha, por exemplo, que o AFIS norte-americano tenha que trocar informações com um futuro AFIS brasileiro. Como os extratores de minúcias utilizados podem ser diferentes, a posição exata das minúcias não será compatível para ambos os sistemas. Isso ocorre pelo fato de não haver uma definição formal de minúcias, ou seja, não existe uma equação matemática que defina o desenho de um fim-de-linha ou de uma bifurcação ideais, por exemplo. Portanto, cada extrator utiliza uma definição de minúcia adotada em particular pelos seus criadores.

Com o objetivo de tornar possível essa troca de informações entre diferentes extratores de minúcias, em (BOLLE, SENIOR, RATHA, PANKANTI, 2002) é utilizada uma definição construtiva de minúcia. A imagem de um fim-de-linha que ocorre na posição $(0,0)$ (origem) com direção de 90° é dada pela equação 3.1.

$$m(x, y) = W(x) \cdot L(y) \quad (\text{eq. 3.1})$$

$$W(x) = \frac{1}{2} \left(1 + \cos \left(\frac{2\pi x}{\beta} \right) \right)$$

$$L(y) = \frac{1}{1 + e^{-y/\alpha}}$$

Onde: β - é o dobro da largura da linha da impressão digital.

α - é um valor proporcional ao tamanho da faixa de transição da função sigmóide $L(y)$, os autores da proposta utilizam $\alpha = \beta / 10$.

A equação 3.1 é o produto de uma senóide com período β , com uma função sigmóide $L(y)$. Observe que os valores de $m(x,y)$ oscilam entre 0 e 1. A Figura 3.15 exhibe a imagem obtida utilizando-se a equação 3.1, mapeando-se os valores 0 e 1 aos tons de cinza branco e preto respectivamente.

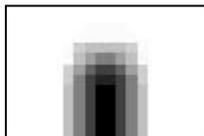


Figura 3.15 – Imagem de um fim-de-linha obtida através da equação 3.1, mapeando-se os valores 0 e 1 nos tons de cinza branco e preto respectivamente.

Da Figura 3.15, pode-se observar que a imagem obtida pela equação 3.1 se assemelha a um fim-de-linha. Uma bifurcação pode ser obtida através da mesma equação, invertendo-se os tons de cinza.

Como dito anteriormente, as posições (x,y) de cada minúcia varia de acordo com o extrator de minúcias utilizado, devido às diferentes definições particulares de minúcias utilizadas por cada autor. Porém, com o uso da eq. 3.1 é possível a elaboração de um método de reposicionamento que altera a posição de uma minúcia, extraída através de algum método, de forma que não importa como ela tenha sido extraída, a minúcia terá sempre a mesma coordena depois de reposicionada.

O método de reposicionamento proposto em (BOLLE, SENIOR, RATHA, PANKANTI, 2002) consiste em encontrar os valores (x,y) de forma a minimizar a função $D(x,y)$ da equação 3.2.

$$D(x,y) = \iint (I(u,v) - m(u',v'))^2 du dv \quad (\text{eq. 3.2})$$

$$\begin{pmatrix} u' \\ v' \end{pmatrix} = \begin{pmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{pmatrix} \begin{pmatrix} u - x \\ v - y \end{pmatrix}$$

Onde: θ - é o ângulo da minúcia.

$I(x,y)$ – Tom de cinza da imagem original na posição (x,y) .

Como as imagens $I(x,y)$ e $m(x,y)$ na prática são discretas, as integrais da eq. 3.2 são substituídas por somatórios de inteiros, e o processo de minimização pode ser feito através do algoritmo de gradiente descendente, derivando-se $D(x,y)$ com relação a x e a y e modificando-se estes valores dando passos no sentido contrário ao gradiente.

Desta forma, aplicando-se o método acima em um conjunto de minúcias, não importará qual extrator foi utilizado para extraí-las, pois as suas posições serão aproximadamente as mesmas.

3.3 Individualidade das Impressões Digitais

Desde do início de século XX as impressões digitais têm sido aceitas em tribunais de justiça pelo fato de não haver duas impressões digitais iguais, ou seja, elas são um tipo de assinatura de uma pessoa. Porém, é necessário saber qual o fundamento científico da afirmação de que “não existem duas impressões digitais iguais”. Nesta seção será visto um modelo, proposto em (MALTONI, MAIO, JAIN, PRABHAKAR, 2003), utilizado para se obter uma estimativa teórica da probabilidade de existirem duas impressões digitais iguais.

Há muito tempo vários cientistas estudam maneiras de se estimar uma probabilidade para o evento de existirem duas impressões digitais iguais. Ao que parece, Galton foi o primeiro cientista que, em seu trabalho (GALTON, 1892), propôs uma forma de se estimar esta probabilidade, baseando-se nos desenhos das linhas da impressão digital.

Neste ponto, cabe fazer a seguinte observação, dois objetos sempre possuem peculiaridades individuais se observados com nível de detalhe suficiente. Por exemplo, dois copos de vidro podem parecer iguais se observados a olho nu, porém, se observados ao microscópio, pode-se notar detalhes nas superfícies de cada copo, que torna possível identificá-los. Portanto, a pergunta é, qual o nível de detalhe ou quantidade de informação deve ser levado em conta ao se comparar duas impressões digitais?

Utilizar toda a informação pode-se tornar impraticável, dependendo da aplicação. Por exemplo, um perito que faz comparação manual, leva em conta as minúcias, os desenhos das linhas e detalhes como cicatrizes e outras marcas. Porém, a maioria dos sistemas automáticos utiliza apenas a informação de minúcias.

Em (MALTONI, MAIO, JAIN, PRABHAKAR, 2003) é proposto um modelo, baseado apenas na informação de minúcias, para se estimar a probabilidade de dois conjuntos de minúcias possuírem uma interseção de uma quantidade específica de minúcias. Este modelo será visto a seguir.

Sejam F e G dois conjuntos de minúcias com cardinalidade m e n respectivamente. Cada minúcia, de F ou G , é constituída de uma tripla (x, y, θ) que contém as suas coordenadas cartesianas e o seu ângulo.

Como a pele é elástica, as minúcias extraídas a partir da coleta de uma impressão digital possuem uma pequena variação em suas posições relativas às outras minúcias, quando comparadas com outras coletas da mesma impressão digital. Por causa disso, será dito que uma minúcia $a = (x_a, y_a, \theta_a)$ corresponde a uma minúcia $b = (x_b, y_b, \theta_b)$ se as seguintes condições forem satisfeitas:

$$\sqrt{(x_a - x_b)^2 + (y_a - y_b)^2} \leq r_0$$

$$\min(|\theta_a - \theta_b|, 360 - |\theta_a - \theta_b|) \leq \theta_0$$

Onde: r_0 – tolerância máxima para as distâncias entre as coordenadas.

θ_0 – tolerância máxima para a diferença dos ângulos.

Suponha que uma impressão digital seja colhida uma vez, gerando o conjunto de minúcias F . Suponha também, que esta mesma impressão seja colhida uma segunda vez, de forma que a impressão esteja transladada e rotacionada acima dos valores de tolerância r_0 e θ_0 , gerando o conjunto de minúcias G . Ou seja, as minúcias de F são basicamente as minúcias de G aplicando-se transformações lineares de translação e rotação. Portanto, apesar de serem minúcias de uma mesma digital, F e G não possuirão minúcias correspondentes.

Portanto, é desejável que um método de comparação de minúcias seja invariante a translação e rotação. Será chamado de alinhamento o processo pelo qual aplica-se, ao conjunto de minúcias F ou G , uma transformação linear de translação e rotação de forma a se obter o máximo de minúcias correspondentes. O processo de alinhamento, através da força bruta, pode ser feito alinhando-se perfeitamente cada uma das n minúcia de G com cada uma das m minúcias de F , e para cada um desses alinhamentos parciais computa-se o número de minúcias correspondentes, guardando-se a transformação que obteve a maior correspondência.

Suponha, portanto, que F e G sejam dois conjuntos de minúcias com, respectivamente, m e n minúcias já alinhadas. Sejam, também, D_F e D_G as imagens das impressões digitais das quais foram extraídos os conjuntos F e G respectivamente, já

rotacionadas e transladadas através da transformação linear obtida pelo processo de alinhamento. Considere também, A como sendo a área de interseção entre D_F e D_G , e C a área de tolerância, ou seja, $C = \pi r_0^2$. A Figura 3.16 ilustra todos esses elementos.

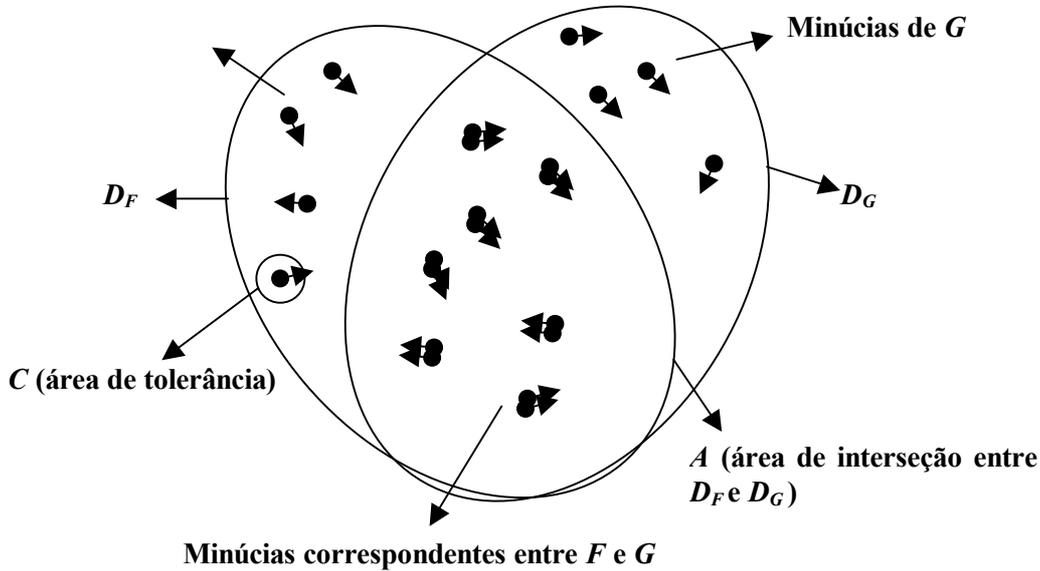


Figura 3.16 – Ilustração dos elementos que serão utilizados para a computação da probabilidade de ocorrer uma correspondência entre dois conjuntos de minúcias.

Neste momento, ignore o ângulo das minúcias e considere somente as suas coordenadas cartesianas. A probabilidade P_C de uma minúcia de G , com coordenadas (x_G, y_G) ser correspondente a uma determinada minúcia de F , com coordenadas (x_F, y_F) é dada pela equação 3.3, a seguir.

$$P_C = P\left(\sqrt{(x_F - x_G)^2 + (y_F - y_G)^2} \leq r_0\right) = \frac{\text{Área de tolerância}}{\text{Área de Interseção}} = \frac{C}{A} \quad (\text{eq. 3.3})$$

Portanto, a probabilidade de uma minúcia de G ser correspondente a pelo menos uma minúcia de F é dada por $m \cdot P_C = mC/A$. Note que o autor não está considerando a possibilidade de que duas minúcias de um mesmo conjunto tenham distância menor do que r_0 , o que é uma suposição razoável se r_0 for suficientemente pequeno.

Suponha, neste momento, que se deseja saber qual a probabilidade de que dadas duas minúcias de G , a primeira possua uma correspondência em F e a segunda não. Este valor é o produto da probabilidade da primeira possuir uma correspondência com a probabilidade da segunda não possuir uma correspondência dado que a primeira possui.

O primeiro termo, como já foi visto, vale mC/A , o segundo termo vale $I - P_C$, porém, o número de minúcias, no segundo termo, não é mais m pois sabe-se que uma dessas minúcias já tem uma correspondência, e a área de interseção deve ser subtraída da área de tolerância, devido a essa correspondência conhecida. Portanto, o segundo termo vale $I - P_C = I - (m - 1)C/(A - C) = \frac{A - C - mC + C}{A - C} = \frac{A - mC}{A - C}$.

Desta forma, a probabilidade de uma minúcia de G possuir uma correspondência em F e a segunda não, é dada por, $\frac{mC}{A} \times \frac{A - mC}{A - C}$.

Generalizando o raciocínio anterior, suponha que se deseja saber qual a probabilidade de ocorrer uma correspondência de exatamente ρ ($\leq \min(m, n)$) minúcias de G com F . Chamando-se esta probabilidade de P_{CME} (Probabilidade de Correspondência Múltipla Exata), ela é dada pelo produto $J \cdot K \cdot L$, cujos significados são descritos a seguir:

- J : é a probabilidade de ocorrerem ρ correspondências, sendo que cada correspondência leva em conta as correspondências anteriores, ou seja, a cada correspondência deve-se subtrair o número de minúcias de 1 e a área de interseção de C . Isto ficará mais claro na fórmula mais adiante;
- K : é a probabilidade de ocorrerem $n - \rho$ não correspondências. Da mesma forma, neste caso devem ser consideradas as não correspondências e correspondências anteriores;
- L : é o número de conjuntos de tamanho ρ que se pode obter a partir de n minúcias.

A equação 3.4 exhibe as fórmulas de J , K , L e P_{CME} .

$$J = \underbrace{\frac{mC}{A} \times \frac{(m-1)C}{A-C} \times \frac{(m-2)C}{A-2C} \times \dots \times \frac{(m-(\rho-1))C}{A-(\rho-1)C}}_{\rho \text{ termos}}$$

$$K = \underbrace{\frac{A-mC}{A-\rho C} \times \frac{A-(m-1)C}{A-(\rho+1)C} \times \dots \times \frac{A-(m-(n-\rho+1))C}{A-(n-1)C}}_{n-\rho \text{ termos}}$$

$$L = \binom{n}{\rho}, \quad P_{CME}(m, n, C, A, \rho) = J \times K \times L \quad (\text{eq. 3.4})$$

A equação de P_{CME} pode ser simplificada se o numerador e o denominador de cada termo de J e K for dividido por C , e substituindo a razão $\frac{A}{C}$ pelo inteiro M que mais se aproxima dela, ou seja, $M = \left\lfloor \frac{A}{C} + 0.5 \right\rfloor$. Esta aproximação é razoável, pois como A é muito maior que C , a parte decimal da razão é desprezível perto da parte inteira. Fazendo-se, portanto, estas substituições, a fórmula de P_{CME} pode ser reescrita de forma mais compacta como exibida na equação 3.5.

$$P_{CME}(m, n, M, \rho) = \frac{\binom{m}{\rho} \binom{M-m}{n-\rho}}{\binom{M}{n}} \quad (\text{eq. 3.5})$$

Para finalizar o cálculo de P_{CME} é necessário apenas incorporar a informação de ângulo das minúcias. Seja t a probabilidade de duas minúcias possuírem uma diferença angular dentro da tolerância, ou seja, $t = P(\min(|\Delta\theta|, 360 - |\Delta\theta|) \leq \theta_0)$, onde $\Delta\theta$ é a diferença entre os ângulos das duas minúcias.

Suponha que haja uma correspondência de coordenadas cartesianas de exatamente ρ minúcias entre F e G . A probabilidade de q ($q \leq \rho$) minúcias desta correspondência tenham ângulos similares é dada por $\binom{\rho}{q} t^q (1-t)^{\rho-q}$.

Portanto, o cálculo de P_{CME} é dado pela equação 3.6.

$$P_{CME}(m, n, M, \rho) = \frac{\binom{m}{\rho} \binom{M-m}{n-\rho}}{\binom{M}{n}} \times \binom{\rho}{q} t^q (1-t)^{\rho-q} \quad (\text{eq. 3.6})$$

A equação 3.6 reflete a probabilidade de ocorrer exatamente ρ correspondências entre minúcias de F e G , considerando as semelhanças cartesianas e angulares. Porém, o desejado é saber qual a probabilidade de ocorrer uma correspondência de pelo menos um determinado número q de minúcias. Para isto, basta somar as probabilidades de ocorrerem as correspondências exatas de tamanho $q, q+1, q+2, \dots, \min(m, n)$. Esta

probabilidade será chamada de P_{CM} (Probabilidade de uma Correspondência Múltipla), e a sua fórmula é dada pela equação 3.7.

$$P_{CM}(m, n, M, q) = \sum_{\rho=q}^{\min(m, n)} P_{CME}(m, n, M, \rho)$$

$$P_{CM}(m, n, M, q) = \sum_{\rho=q}^{\min(m, n)} \left(\frac{\binom{m}{\rho} \binom{M-m}{n-\rho}}{\binom{M}{n}} \times \binom{\rho}{q} t^q (1-t)^{\rho-q} \right) \quad (eq. 3.7)$$

Para que a fórmula de P_{CM} possa ser utilizada é necessário estimar seus parâmetros, m , n , q , A , r_0 e θ_0 . Para isto, os autores do método utilizaram uma base de imagens de impressões digitais com 500 ppp de resolução, e fizeram uma estimativa empírica da seguinte forma; para cada imagem foram extraídos dois conjuntos de minúcias, um de forma automática e outro manualmente por peritos. Os peritos fizeram manualmente as correspondências entre minúcias dos dois conjuntos de cada imagem. Desta forma, A pode ser estimado como o valor médio das interseções das correspondências manuais.

O valor escolhido para r_0 foi de 15 pixels, o que pelos testes demonstrou que 97,5% das minúcias que foram correspondidas manualmente estão dentro desta tolerância.

O valor escolhido para θ_0 foi de $22,5^\circ$, pois os testes demonstraram que as diferenças angulares de 97,5% das minúcias correspondentes estão dentro desta tolerância. Portanto, $t = P(\min(|\Delta\theta|, 360 - |\Delta\theta|) \leq 22,5) = \frac{22,5}{180} = 0,125$.

Em um tribunal, geralmente se utilizam impressões digitais latentes, das quais não se consegue extrair grandes quantidades de minúcias. Suponha que apenas 12 minúcias tenham sido extraídas de uma impressão latente, e que haja uma correspondência delas com 12 minúcias de uma imagem colhida de um suspeito.

Supondo-se que:

- $M = 70$, o que é uma estimativa realista quando se trata de imagens com poucas minúcias (MALTONI, MAIO, JAIN, PRABHAKAR, 2003);
- $n = 12$, o número de minúcias extraídas da impressão latente;

- $m = 60$, o número de minúcias extraídas da impressão no momento em que o suspeito foi preso. O valor de m é maior que de n , pois durante uma coleta controlada mais minúcias são encontradas.

Utilizando-se estes valores na equação 3.7, teremos uma estimativa da probabilidade das duas impressões digitais (a latente e a colhida normalmente) não serem a mesma, dado que existe uma correspondência de 12 minúcias entre elas. Este valor é $P_{CM}(12,60,70,12) = 1,914 \times 10^{-12}$. Por isso, uma correspondência de 12 ou mais minúcias entre duas impressões digitais é considerada evidência mais que suficiente de que as duas impressões digitais são a mesma.

Portanto, a probabilidade de ocorrência de duas impressões digitais iguais na natureza é menor ou igual a probabilidade estimada através de P_{CM} . Deve-se notar também, que conforme o número de minúcias aumenta, a probabilidade cai rapidamente, por exemplo, se ao invés de 12 minúcias tivessem sido utilizadas 13, o valor de P_{CM} iria para $1,98 \times 10^{-13}$. Ou seja, o acréscimo de uma única minúcia fez com que a probabilidade caísse uma ordem de grandeza. A Figura 3.17 exhibe o gráfico de P_{CM} para diversos valores de correspondência.

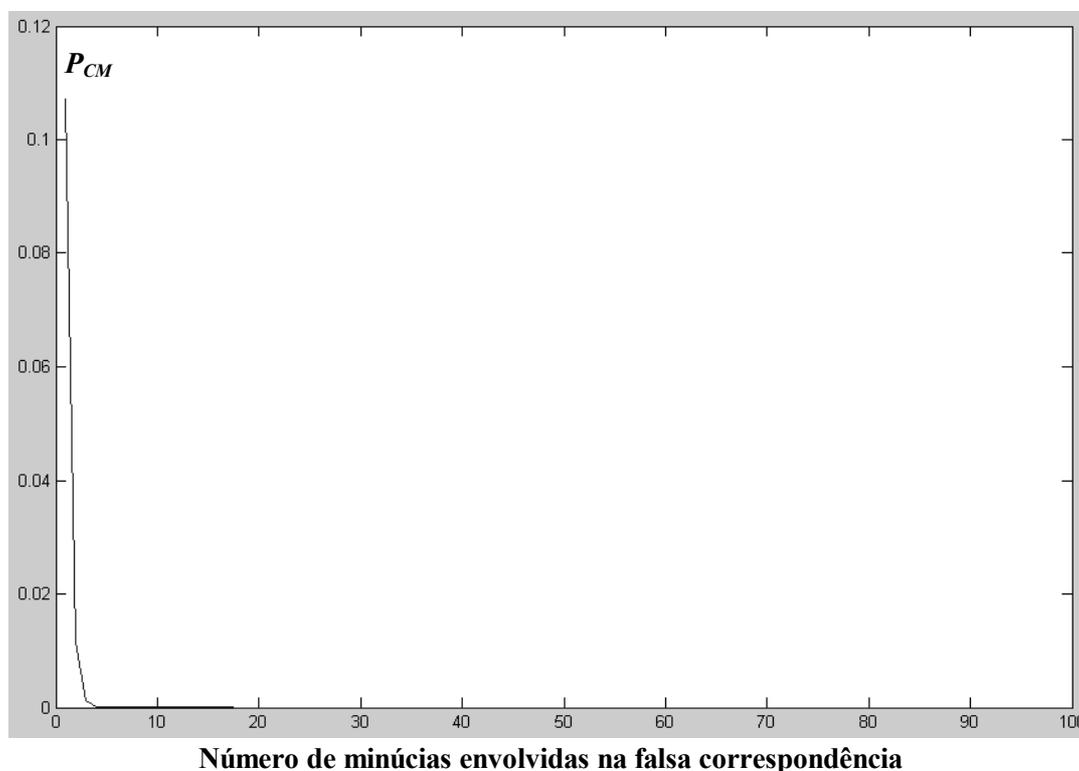


Figura 3.17 – Gráfico de P_{cm} , que representa a probabilidade de ocorrer uma falsa correspondência para diferentes quantidades de minúcias envolvidas.

3.4 Considerações Finais

Durante este capítulo foi visto que as impressões digitais são formadas por processos genéticos e ambientais. Este segundo processo garante um nível grande de aleatoriedade à formação das linhas da impressão digital, garantindo assim, que a existência de duas impressões digitais iguais seja extremamente improvável de ocorrer. Da seção anterior concluiu-se que, considerando-se somente a informação das minúcias, esta probabilidade é muito inferior a $1,98 \times 10^{-13}$, pois naquele exemplo foram consideradas apenas treze minúcias, enquanto que na prática, uma impressão digital possui em média 60 minúcias. Além disso, existem outras informações agregadas a uma impressão digital, como presença de cicatrizes e tipos de desenhos das linhas (arco, verticilo e etc), que são utilizadas por peritos no momento da comparação.

Em sistemas automáticos, as minúcias são muito utilizadas, pois possuem muita informação discriminativa. Apesar de vários cientistas terem estudado o problema de detecção automática de minúcias durante vários anos, este problema ainda não tem solução boa para imagens de média e baixa qualidade.

No Capítulo 6 deste trabalho é proposto um método que utiliza redes neurais para a extração de minúcias em imagens, que em sua maioria possuem qualidade média, apesar de haver imagens de qualidade boa e péssima. As imagens possuem esta qualidade, pois foram obtidas de arquivos cujo objetivo não era de se utilizar em um sistema totalmente automático, mas semi-automático, por isso a qualidade da imagem não foi uma preocupação extrema no momento da coleta.

4 TRATAMENTO DA IMAGEM

Como mencionado no Capítulo 3, antes de se extrair as características de um dado biométrico é necessária uma fase de pré-processamento, que consiste basicamente na aplicação de filtros que melhorem ou realcem qualidades presentes nos dados.

Como o foco desta dissertação é a extração de minúcias a partir da imagem de uma impressão digital, são apresentados neste capítulo dois filtros de amplo conhecimento na área de processamento de imagens, que são a equalização de histograma (GONZALEZ; WOODS, 2000) e o filtro de Gabor (HONG, WAN, JAIN, 1998; LEUNG, ENGELER, FRANK, 1990). Estes filtros são estudados respectivamente nas duas próximas seções. Na 3ª e última seção é feita uma proposta de uso de uma rede neural para aproximação do filtro de Gabor.

Durante este capítulo é considerado apenas o uso de imagens em tons de cinza, portanto uma imagem é tida como uma matriz I em que cada um de seus elementos (pixels) pode assumir qualquer valor inteiro no intervalo $[0, 255]$, onde o zero representa o tom de cinza mais escuro (preto) e o 255 o mais claro (branco).

4.1 Equalização de Histograma

A equalização de histograma é um filtro que tem por objetivo aumentar o contraste de tons de cinza de uma imagem. O histograma de uma imagem consiste em um vetor de 256 posições onde cada posição k indica quantas vezes o tom de cinza k ocorre na imagem. A Figura 4.1 exibe a imagem de uma impressão digital e a Figura 4.2 o seu respectivo histograma.

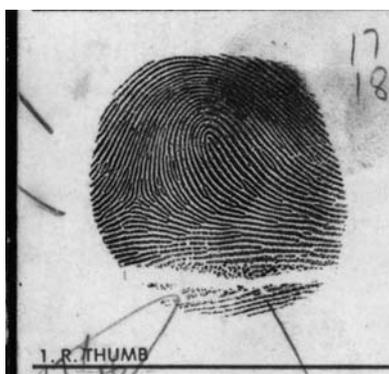


Figura 4.1 – Imagem de uma impressão digital.

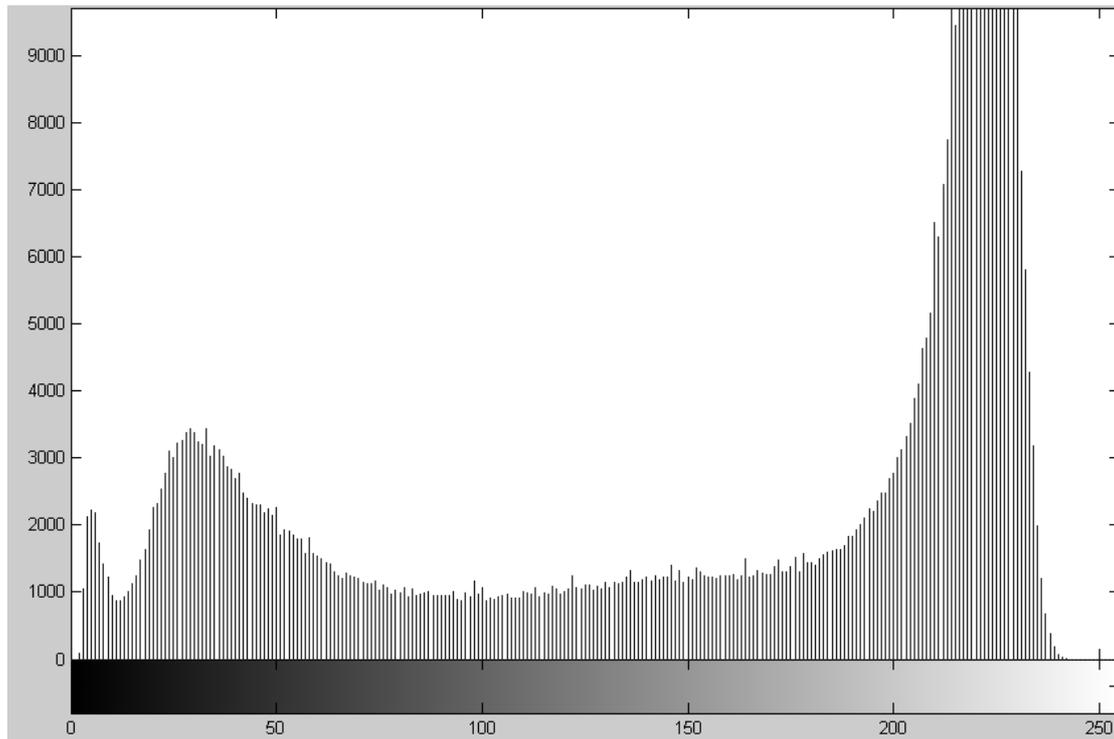


Figura 4.2 – Histograma da imagem da Figura 4.1.

O histograma é, portanto, uma informação estatística da imagem que revela como os tons de cinza estão distribuídos. A partir do histograma pode-se definir uma função $p(k)$ que representa a probabilidade de ocorrência de um determinado tom de cinza k . A equação 4.1 exhibe esta definição.

$$p(k) = \frac{h(k)}{\sum_{i=0}^{255} h(i)} \quad (\text{eq. 4.1})$$

Onde h é o histograma e $h(k)$ é o número de vezes que o tom de cinza k ocorre na imagem.

Uma imagem de baixo contraste é aquela em que os tons de cinza estão concentrados em uma pequena região do histograma. A Figura 4.3 exhibe duas imagens de baixo contraste, uma com concentração dos tons de cinza em uma região alta (clara) do histograma e outra com concentração em uma região baixa (escura) do histograma.



Figura 4.3 – (a) Imagem clara de baixo contraste. (b) Imagem escura de baixo contraste.

A Figura 4.4 exibe os histogramas das figuras 4.3(a) e 4.3(b). Observe a concentração dos níveis de cinza em regiões específicas do histograma.

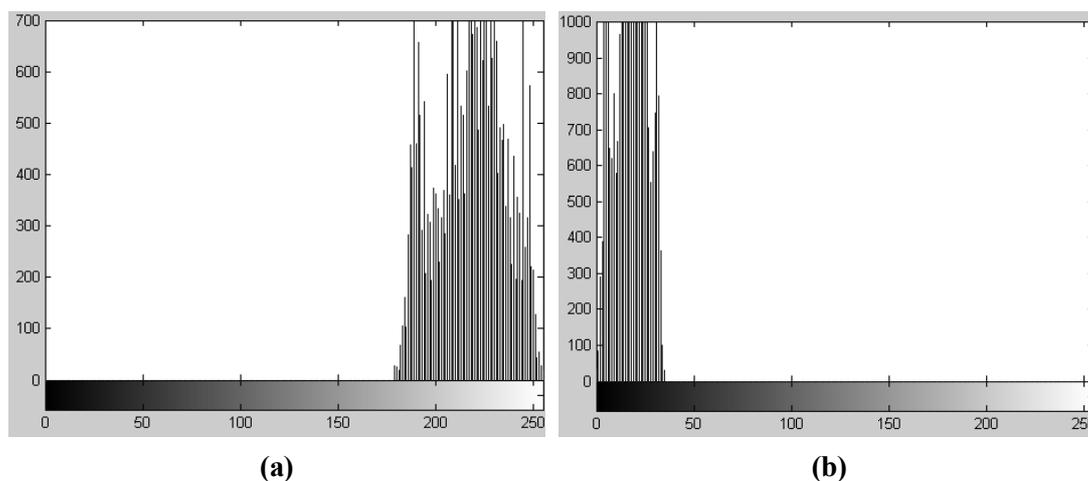


Figura 4.4 – (a) Histograma da Figura 4.3(a), observe como os tons de cinza se concentram nas regiões mais altas do histograma ao contrário da Figura 4.3(b) onde os tons de cinza se concentram mais nas regiões baixas do histograma (b).

O processo de equalização de histograma (GONZALEZ, WOODS, 2000) tem como objetivo redistribuir os tons de cinza da imagem de forma a tornar o histograma mais uniforme.

Para descrever melhor o processo de equalização considere a seguinte definição dada pela equação 4.2:

$$p(x) = \begin{cases} f(x) & \text{se } 0 \leq x \leq 1 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{eq. 4.2})$$

Onde $f(x)$ é uma função contínua no intervalo $[0,1]$ e $\int_0^1 f(x)dx = 1$.

Na definição acima, x representa uma variável e $p(x)$ representa a densidade de probabilidade da variável x (HOEL, PORT, STONE, 1978). Definindo-se uma variável y de acordo com a equação 4.3 é obtida uma nova variável cuja densidade de probabilidade é uniforme.

$$y(x) = \int_0^x p(w) dw \quad (\text{eq. 4.3})$$

A Figura 4.5 apresenta um exemplo das distribuições das variáveis x e y .

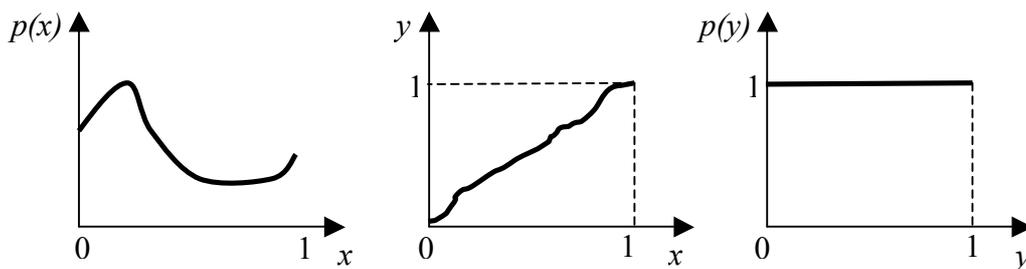


Figura 4.5 – Da esquerda para a direita tem-se a distribuição da variável x , a definição da variável y e a distribuição de probabilidade de y .

Observe que y é uma função de x e que possui uma distribuição uniforme. Portanto, se x representa os tons de cinza de uma imagem I , pode-se criar uma nova imagem I_e substituindo cada tom de cinza x pelo tom de cinza y correspondente através da equação 4.3 e, portanto, a nova imagem I_e possuirá densidade de probabilidade uniforme, já que seus tons de cinza são dados pela variável y .

Portanto, a partir da equação 4.3 é possível obter uma imagem equalizada (com histograma equalizado) a partir de uma outra imagem, senão fossem os seguintes problemas:

- o histograma de uma imagem não é uma função de probabilidade, porém este problema é resolvido utilizando-se a equação 4.1;

- o histograma não está definido no intervalo [0,1] e sim no intervalo [0,255], contudo este problema é resolvido através de um simples reescalonamento linear;

- o histograma de uma imagem digital é discreto e a eq. 4.3 diz respeito a uma função contínua. Este problema não tem solução, o que se pode fazer é substituir a integral da eq. 4.3 por um somatório e obter uma aproximação da fórmula de equalização. A equação 4.4 apresenta a fórmula que mapeia um tom de cinza k de uma imagem em um novo tom de cinza v que irá compor a nova imagem equalizada.

$$v = \frac{255 \cdot \sum_{i=0}^k h(i)}{\sum_{j=0}^{255} h(j)} \quad (eq. 4.4)$$

Aplicando-se a fórmula da equação 4.4 nas imagens da Figura 4.3 são obtidas as imagens da Figura 4.6.



Figura 4.6 – (a) Imagem da Figura 4.3(a) após a equalização. (b) Imagem da Figura 4.3(b) após a equalização.

A Figura 4.7 exhibe os histogramas das figuras 4.6, observe que apesar de não ser uma distribuição uniforme, cada histograma apresenta uma distribuição mais equalizada.

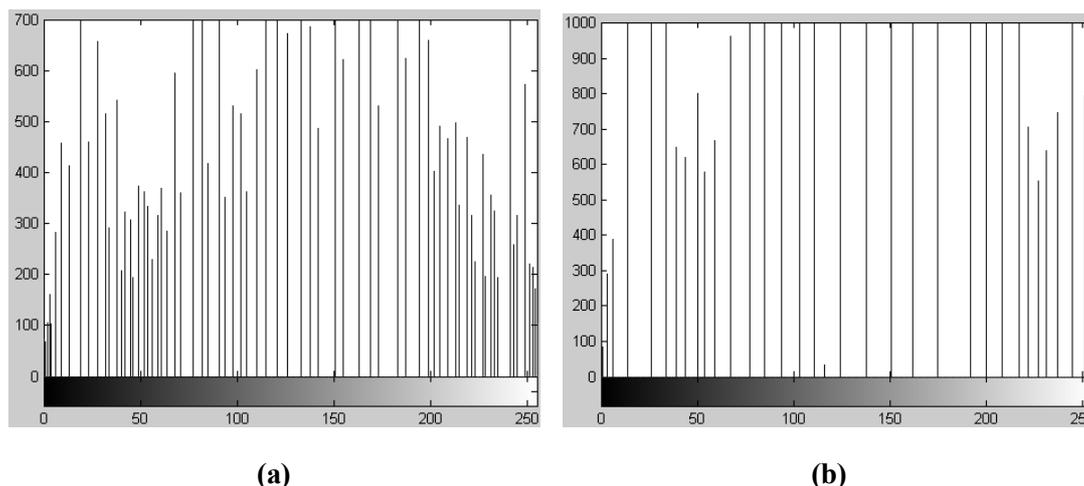


Figura 4.7 – Histogramas das figuras 4.6(a) e (b) respectivamente. Apesar da distribuição não ser uniforme, os tons de cinza estão mais bem distribuídos.

Para se extrair minúcias de uma impressão digital, tanto manual como automaticamente, é desejável que o contraste entre o fundo e as linhas da impressão digital seja alto. Porém, em uma imagem de impressão digital podem existir regiões com níveis de contraste variável, que podem ser basicamente descritos como:

- **regiões escuras de baixo contraste:** são regiões onde o fundo, que geralmente é claro, se confunde com as linhas da impressão digital, que geralmente são escuras. Isto geralmente ocorre por se ter utilizado muita tinta na coleta, ou porque foi feita muita pressão contra o papel naquela região;

- **regiões claras de baixo contraste:** estas regiões são o contrário das descritas anteriormente. Nestas regiões as linhas da impressão digital são confundidas com o fundo, geralmente por se ter utilizado pouca tinta ou porque não foi feita pressão suficiente para que o papel absorvesse a tinta de forma adequada;

- **regiões com bom contraste:** são regiões em que a diferença entre o fundo e as linhas da impressão digital é nítida.

A Figura 4.8 exhibe os tipos de regiões descritos acima. O ideal é que os contrastes de níveis de cinza em todas as regiões da imagem sejam iguais. Se o processo de equalização gerasse um histograma uniforme, isso garantiria um nível de contraste igual em todas as regiões da imagem, já que a imagem possuiria uma distribuição de níveis de cinza uniforme. Porém, como visto, devido ao fato da imagem consistir em um sinal discreto e não contínuo, a uniformização de seu histograma não pode ser realizado

de forma ideal. A Figura 4.9 exibe a imagem da Figura 4.8 após o processo de equalização.

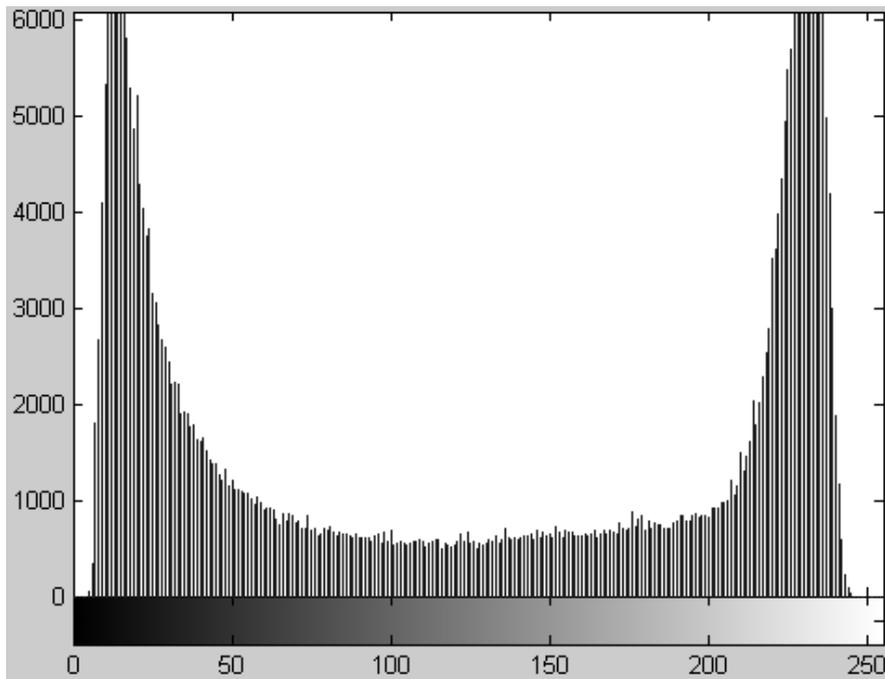


Figura 4.8 – Esta imagem possui regiões com bom contraste entre o fundo e as linhas da impressão digital e possui regiões escuras e claras de baixo contraste.

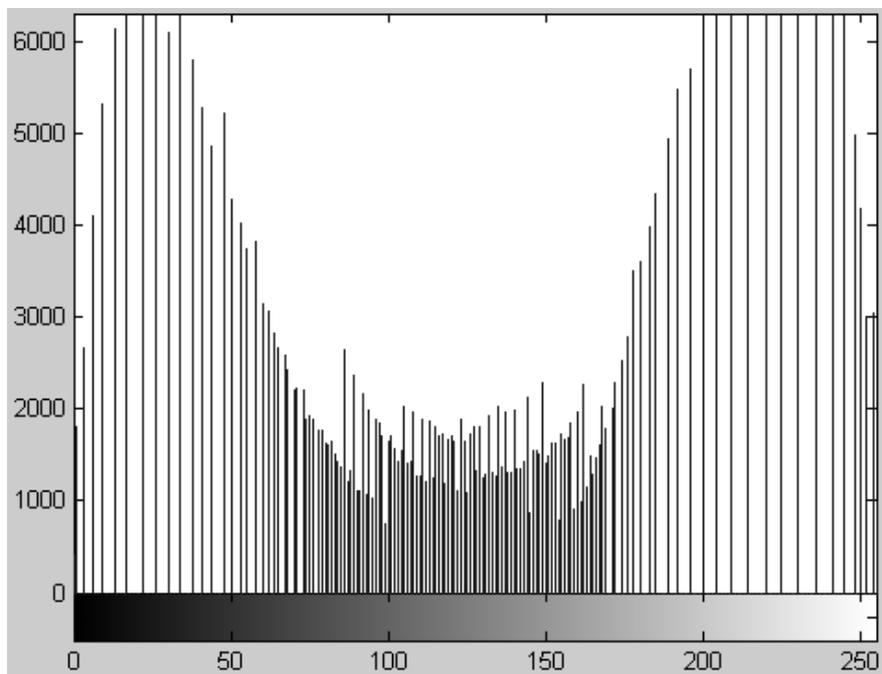


Figura 4.9 – Imagem da Figura 4.8 após a equalização. Apesar do contraste ter melhorado nas áreas de baixo contraste, ele piorou nas regiões que já tinham um bom contraste.

A Figura 4.10 exibe os histogramas das imagens das figuras 4.8 e 4.9.



(a)



(b)

Figura 4.10 – (a) Histograma da Figura 4.8. (b) Histograma da Figura 4.9, que é a imagem da Figura 4.8 após o processo de equalização.

O que se pode observar da Figura 4.9 é que o contraste aumentou nas regiões que tinham baixo contraste, tanto as regiões escuras como claras, e diminuiu nas regiões que já tinham bom contraste, o que é um problema. Outro problema é que os níveis de contraste ao longo das regiões da impressão digital não são iguais, e o que se deseja é um nível de contraste uniforme. Uma maneira de se atingir esta uniformização dos tons de cinza é aplicar uma equalização local, que consiste em dividir a imagem em sub-imagens e aplicar o processo de equalização (eq. 4.4) em cada uma delas. A Figura 4.11 exibe a imagem da Figura 4.8 aplicando-se uma equalização local onde a imagem foi subdividida em quadrados não superpostos de 16x16 pixels. Cada um desses blocos foi equalizado como se fosse uma imagem independente, utilizando-se a fórmula da equação 4.4.

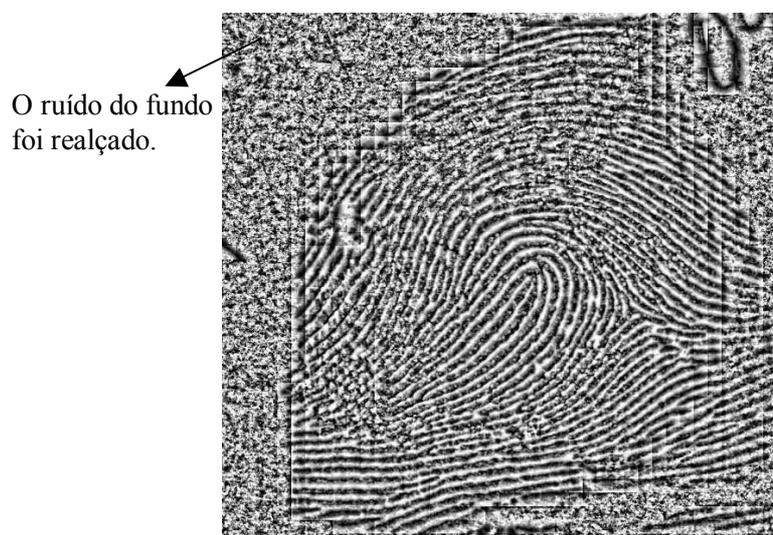


Figura 4.11 – Imagem da Figura 4.8 após a equalização local utilizando, como sub-imagens, blocos não superpostos de 16x16 pixels. Observe que o nível de contraste ao longo da digital ficou bem uniforme.

Como observado na Figura 4.11 o nível de contraste ao longo das regiões da impressão digital ficou mais uniforme, ou seja, o contraste nas regiões que tinham baixo contraste ficou bem parecido com o contraste nas regiões que já tinham um bom contraste. Visualmente a imagem parece ter uma qualidade pior do que antes de equalização, pois apesar de teoricamente o fundo ser todo branco, por diversas razões existem pequenas variações de tons de branco no papel que são realçadas quando é aplicada a equalização local. A Figura 4.12 exibe a imagem 4.8 aplicando-se a equalização local somente nas regiões que fazem parte da impressão digital, criando

uma imagem que visualmente parece ter uma qualidade melhor do que da Figura 4.8, 4.9 e 4.11.

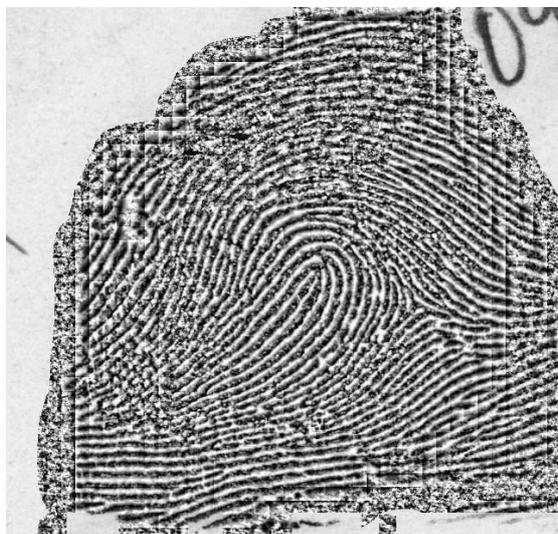


Figura 4.12 – Imagem da Figura 4.8 após a equalização local aplicada somente nas regiões que fazem parte da impressão digital.

A Figura 4.13 exibe os histogramas das figuras 4.9 e 4.11. Observe que o histograma da Figura 4.11 é mais uniforme do que da Figura 4.9, apesar da Figura 4.9 ser o resultado da equalização da imagem da Figura 4.8.

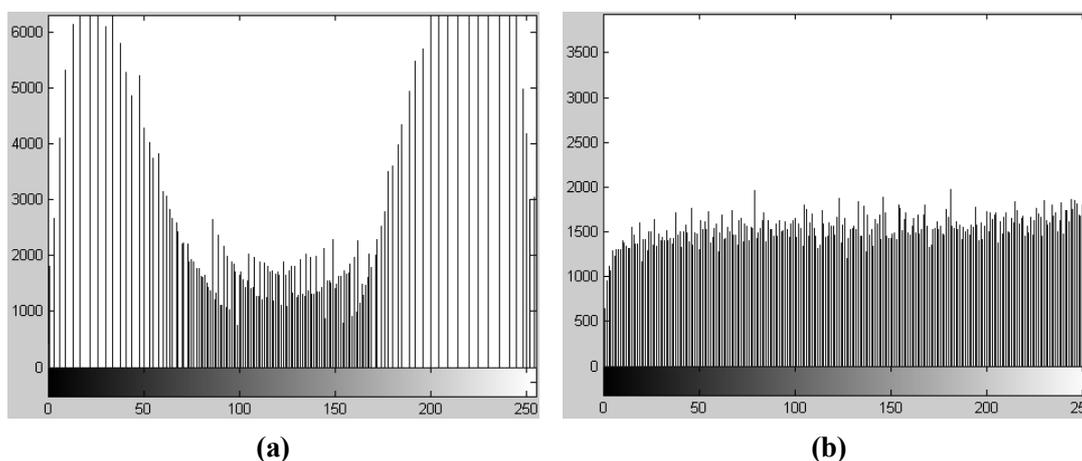


Figura 4.13 – (a) Histograma da imagem da Figura 4.9 que é uma imagem equalizada. (b) Histograma da imagem da Figura 4.11 que é uma imagem equalizada localmente. Observe que o histograma está bem mais uniforme do que (a).

Apesar dos níveis de cinza ficarem mais bem distribuídos, a equalização local feita desta forma traz uma desvantagem, que é a descontinuidade dos níveis de cinza

entre os pixels das bordas entre os blocos. Suponha dois pixels p_0 e p_1 com coordenadas (x,y) e $(x+1,y)$ respectivamente. Esses dois pixels são vizinhos em colunas e, portanto, os seus níveis de cinza devem ser parecidos um com o outro na imagem original. Porém, suponha que p_0 pertença a um bloco e p_1 a outro. Como cada bloco é equalizado em separado, não necessariamente os novos níveis de cinza de p_0 e p_1 terão valores próximos, criando uma mudança brusca que não existia na imagem original, fazendo com que a imagem final fique com um aspecto quadriculado. A Figura 4.14 exibe um fragmento ampliado da imagem da Figura 4.11 para exemplificar esta situação.

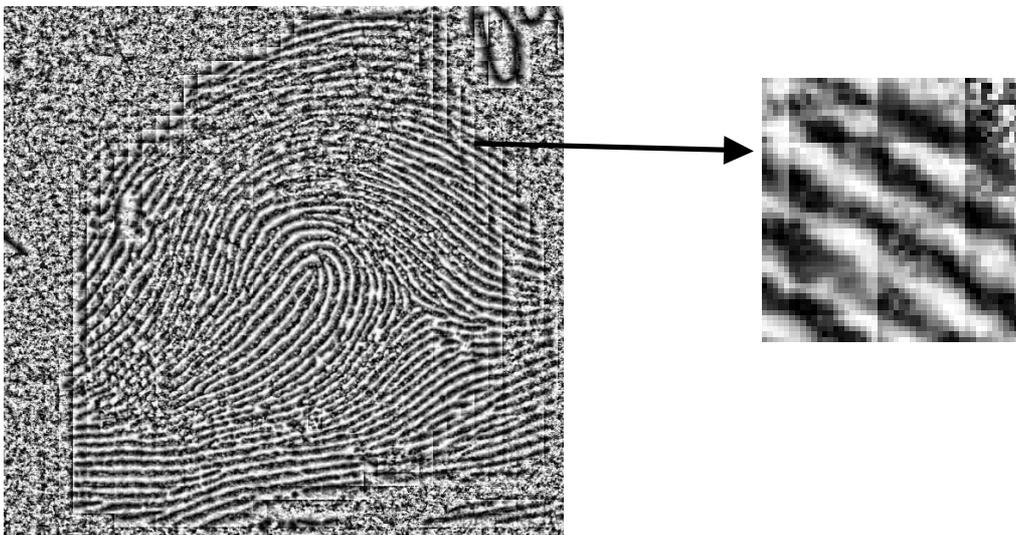


Figura 4.14 – Imagem da Figura 4.11. Observe como o fragmento ampliado apresenta um aspecto quadriculado porque a equalização é feita em cada bloco de forma independente.

4.2 Equalização Local – Proposta de uma nova abordagem

Nesta seção faz-se a proposta de uma forma de se eliminar este efeito quadriculado e ainda assim obter os benefícios trazidos pela equalização local. A idéia básica consiste em enxergar a equação 4.4, que é repetida abaixo, como uma função que mapeia um tom de cinza k em um novo tom de cinza v , ou seja, v é uma função de k .

$$v(k) = \frac{255 \cdot \sum_{i=0}^k h(i)}{\sum_{j=0}^{255} h(j)} \quad (\text{eq. 4.4})$$

Na equalização local a imagem é dividida em blocos quadrados por simplicidade. Cada bloco será identificado por $B_{i,j}$ onde i e j são suas posições horizontal e vertical respectivamente. A Figura 4.15 ilustra esta notação.

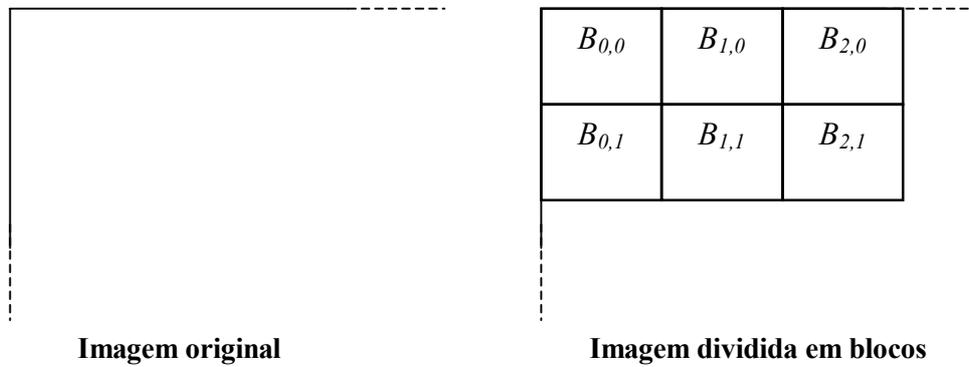


Figura 4.15 – Na equalização local a imagem é dividida em blocos que são identificados por suas posições horizontal e vertical.

Como a equalização é aplicada em cada bloco, tem-se uma função $v(k)$ para cada bloco, que será denotada por $v_{i,j}(k)$ para a função de mapeamento do bloco $B_{i,j}$. Para se evitar o efeito de quadriculado é necessário que o nível de cinza de cada pixel seja baseado nas funções de mapeamento $v_{i,j}(k)$ dos blocos mais próximos dele. Ou seja, é necessário percorrer a imagem pixel a pixel e fazer uma interpolação dos valores das funções de mapeamento de acordo com a proximidade do pixel corrente para os centros dos blocos mais próximos. Neste estudo foi escolhido utilizar uma função de interpolação bilinear que consiste em interpolar as funções de mapeamento dos 4 blocos mais próximos do pixel. Esta função de interpolação é simples e traz bons resultados. Para que este método seja melhor explicado considere as seguintes notações:

Seja b – tamanho, em pixels, de um lado do bloco, que no caso é 16.

$$n = \begin{cases} \left\lfloor \frac{2 \cdot x - b}{2 \cdot b} \right\rfloor, & \text{se } \frac{b}{2} \leq x \leq L - \frac{b}{2} \\ 0, & \text{se } x < \frac{b}{2} \\ \frac{L}{b} - 1, & \text{se } L - \frac{b}{2} < x \end{cases} \quad m = \begin{cases} \left\lfloor \frac{2 \cdot y - b}{2 \cdot b} \right\rfloor, & \text{se } \frac{b}{2} \leq y \leq A - \frac{b}{2} \\ 0, & \text{se } y < \frac{b}{2} \\ \frac{A}{b} - 1, & \text{se } A - \frac{b}{2} < y \end{cases}$$

$$\begin{aligned} xc &= n \cdot b + \frac{b}{2} & yc &= m \cdot b + \frac{b}{2} \\ \Delta x &= x - xc & \Delta y &= y - yc \end{aligned}$$

Onde A e L são, respectivamente a altura e a largura da imagem.

As notações anteriores são ilustradas graficamente na Figura 4.16.

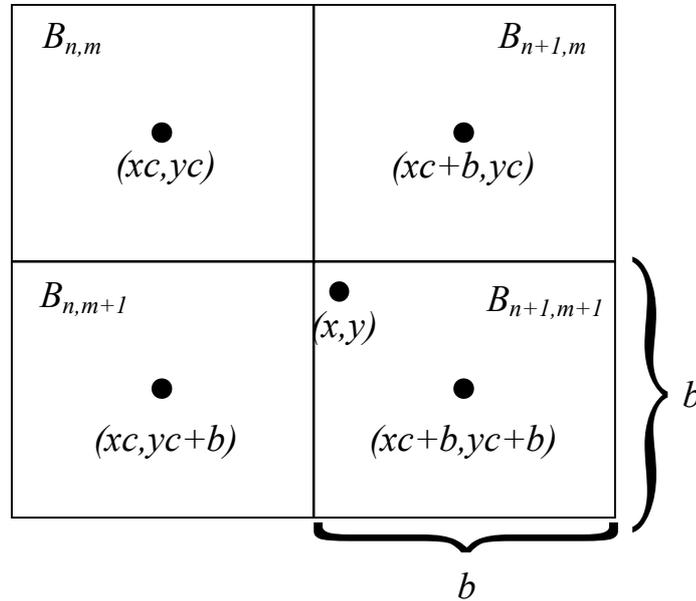


Figura 4.16 – Ilustração gráfica das notações para a explicação da equalização local interpolada.

Da figura, tem-se que para cada pixel de coordenada (x,y) existem quatro blocos mais próximos que são $B_{n,m}$, $B_{n,m+1}$, $B_{n+1,m}$ e $B_{n+1,m+1}$, cujas coordenadas dos centros são respectivamente (xc,yc) , $(xc,yc+b)$, $(xc+b,yc)$ e $(xc+b,yc+b)$. Portanto, dx e dy são as distâncias horizontal e vertical do pixel para o bloco $B_{n,m}$.

Dadas estas definições, o nível de cinza do pixel de coordenada (x,y) será calculada pela equação 4.5

$$v(k, x, y) = px \cdot py \cdot v_{n,m}(k) + px \cdot (1 - py) \cdot v_{n,m+1}(k) + (1 - px) \cdot py \cdot v_{n+1,m}(k) + (1 - px) \cdot (1 - py) \cdot v_{n+1,m+1}(k) \quad (\text{eq. 4.5})$$

$$\text{Onde: } px = 1 - \frac{\Delta x}{b}$$

$$py = 1 - \frac{\Delta y}{b}$$

k – nível de cinza do pixel de coordenada (x,y) na imagem original.

$v_{i,j}(k)$ – função de mapeamento do bloco $B_{i,j}$.

A Figura 4.17 exibe o resultado desta equalização local interpolada na imagem da Figura 4.8.

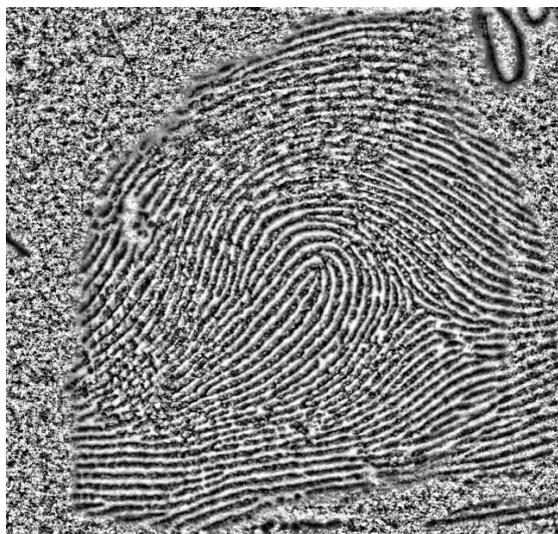


Figura 4.17 – Imagem da Figura 4.8 após a equalização local interpolada.

A Figura 4.18 exibe o histograma da imagem após a equalização interpolada, observe que o histograma ainda se mantém aproximadamente uniforme.

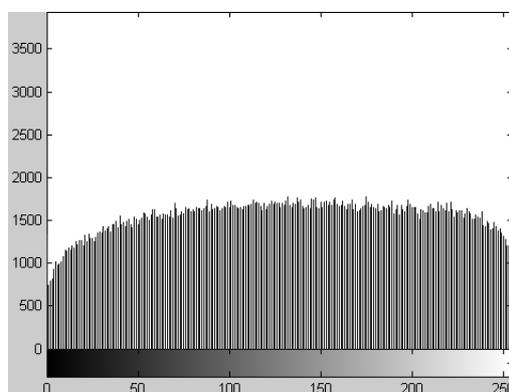


Figura 4.18 – Histograma da imagem da Figura 4.17, observe que se aproxima de uma distribuição uniforme.

A Figura 4.19 exibe a imagem da Figura 4.8 e a sua equalização local interpolada aplicada somente nas áreas que possuem impressão digital.



Figura 4.19 – (a) Imagem da Figura 4.8, com regiões de baixo contraste. (b) Imagem de (a) após a equalização local interpolada. O contraste ficou aproximadamente uniforme ao longo da impressão digital.

A Figura 4.20 exibe o fragmento da Figura 4.14 após o processo de equalização interpolada. Observe que o efeito de quadriculado foi removido.

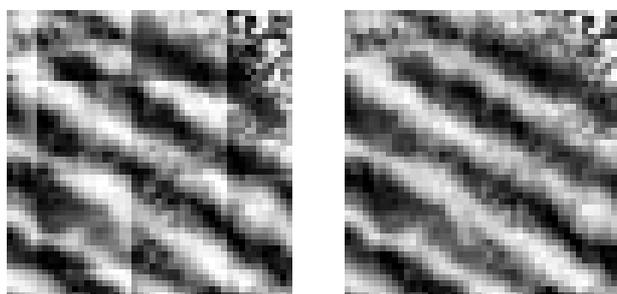


Figura 4.20 – À esquerda um fragmento da imagem 4.8 equalizada localmente, à direita o mesmo fragmento após a equalização local interpolada. Observe que o efeito de quadriculado presente na imagem da esquerda foi removido.

4.3 Filtro de Gabor

O filtro de Gabor é utilizado em muitos contextos com diferentes finalidades. Contudo, em impressões digitais seu principal uso se dá no processo de recuperação da qualidade da imagem, como proposto em (HONG, WAN, JAIN, 1998).

A função básica do filtro de Gabor é realçar a qualidade de imagens senoidais, aumentando o contraste e suprimindo ruídos. Porém, antes de se estudar o filtro para a sua utilização em imagens digitais, é melhor estudá-lo no domínio contínuo.

O filtro de Gabor consiste em um filtro linear bi-dimensional invariante de deslocamento, portanto ele pode ser representado através de uma função de convolução que consiste na resposta ao impulso do filtro (JAIN, 1989). A equação 4.6 apresenta a resposta ao impulso do filtro de Gabor (HONG, WAN, JAIN, 1998).

$$G(x, y, f) = \exp\left(-0.5 \cdot \left(\frac{x^2}{gx^2} + \frac{y^2}{gy^2}\right)\right) \cdot \cos(2 \cdot \pi \cdot f \cdot y) \quad (\text{eq. 4.6})$$

Onde o significado das variáveis x, y, f, gx e gy serão explicados mais adiante.

A Figura 4.21 apresenta graficamente o filtro no intervalo $[-15:15, -15:15]$ das coordenadas x e y , utilizando $f = 1/10$ e $gx = gy = 4$.

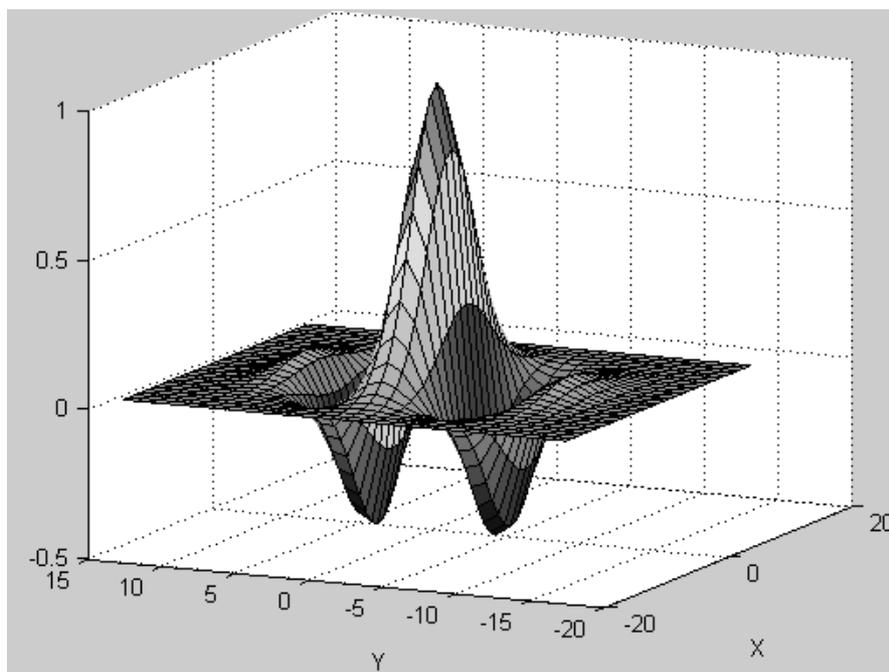


Figura 4.21 – Resposta ao impulso do filtro de Gabor no intervalo $[-15:15, -15:15]$, utilizando $gx = gy = 4$ e $f = 1/10$.

Analisando-se a equação 4.6, pode-se observar que o filtro de Gabor consiste no produto de uma gaussiana, simétrica em relação à origem, e uma função cossenooidal, com frequência f , ao longo do eixo y . Isso faz com que o filtro aumente o realce de

senóides com frequência f ao longo do eixo y ao mesmo tempo em que atua como um filtro passa-baixa ao longo dos eixos y e x principalmente.

Em imagens digitais o filtro não pode ser contínuo, mas discreto e finito. A sua aplicação é feita através de uma matriz de convolução, que consiste em amostrar a equação 4.6 em um domínio finito e convoluí-la com a imagem a ser realçada. Após a operação de convolução é necessário truncar a imagem caso os valores ultrapassem 255 ou fiquem menores do que 0. A Figura 4.22 exibe uma imagem senoidal com frequência $f = 1/10$ e a imagem convolvida com um filtro de Gabor com a mesma frequência, usando uma matriz de convolução de 31x31 pixels. Observe como as linhas da senóide ficaram mais realçadas.

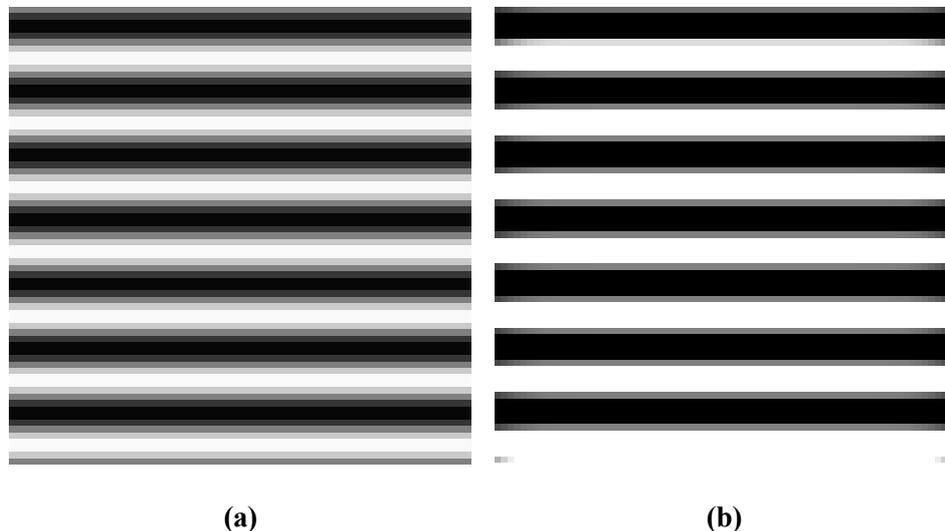


Figura 4.22 – (a) Imagem de uma senóide com frequência 1/10. (b) Imagem da senóide após a convolução com o filtro, o contraste foi aumentado.

Da Figura 4.22 tem-se a impressão de que o filtro de Gabor transformou a imagem, que era um sinal senoidal, em um sinal quadrado. Isto ocorre devido ao truncamento, porque os pixels que ultrapasaram o valor de 255 foram truncados para 255 e aqueles com valores abaixo de 0 foram truncados para 0. A Figura 4.23 ilustra esta situação exibindo um corte da senóide, a sua resposta ao filtro e o truncamento.

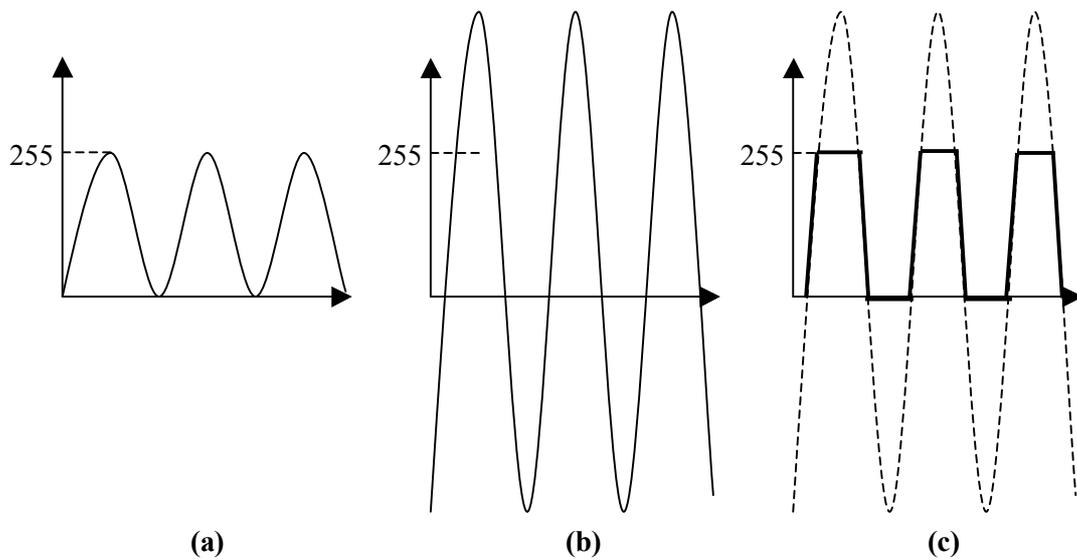


Figura 4.23 – (a) Corte de uma senóide bidimensional. (b) Resposta do filtro ao sinal de (a), o sinal foi realçado aumentando a amplitude da senóide. (c) A senóide (b) deve ser truncada, criando um sinal semelhante a um sinal quadrado.

Como mencionado, o filtro de Gabor age como um filtro passa-baixa ao longo dos eixos x e y , suprimindo ruídos. A Figura 4.24 exibe uma imagem de uma senóide com alguns ruídos e a imagem resultante da convolução com o filtro. Observe como a imagem se assemelha a da Figura 4.22 (b).

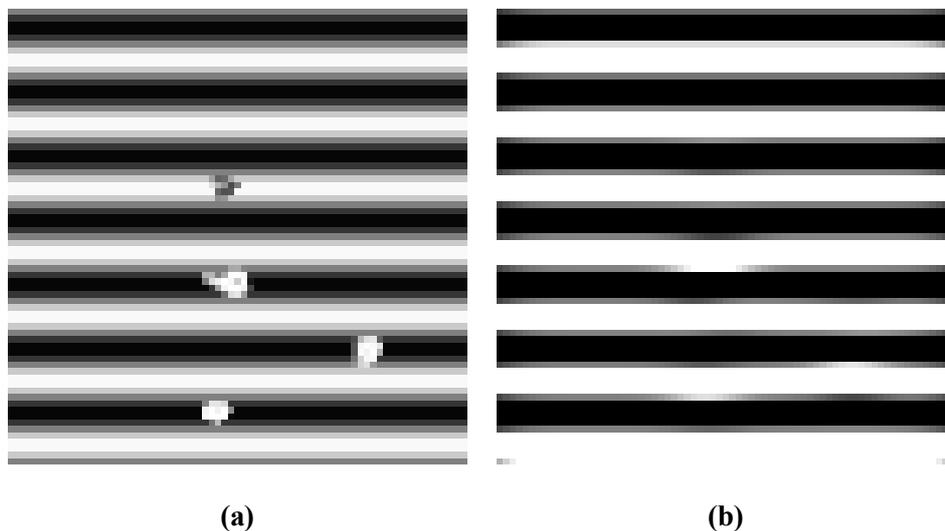


Fig. 4.24 – (a) Imagem da fig. 4.22 (a) com alguns ruídos. (b) A imagem após a convolução com o filtro de Gabor. Note como a imagem ficou semelhante à da Figura 4.22 (b).

Para finalizar o entendimento do filtro Gabor, antes de ver a sua aplicação em impressões digitais, é necessário analisar a sua resposta no domínio da frequência. A equação 4.7 apresenta a eq. 4.6 escrita de uma forma diferente.

$$G(x, y, f) = W(x, y) \cdot V(y, f) \quad (\text{eq. 4.7})$$

onde

$$W(x, y) = \exp\left(-0.5 \cdot \left(\frac{x^2}{gx^2} + \frac{y^2}{gy^2}\right)\right)$$

$$V(y, f) = \cos(2 \cdot \pi \cdot f \cdot y)$$

Da equação acima se tem que o filtro de Gabor $G(x, y, f)$ é o produto de uma Gaussiana $W(x, y)$ com uma função cosseno $V(y, f)$ de frequência f . Portanto, a transformada de Fourier de $G(x, y, f)$, denotada por $\mathcal{F}\{G(x, y, f)\}$, é a convolução da transformada de Fourier de $W(x, y, f)$ com a transformada de $V(y, f)$, denotadas respectivamente por $\mathcal{F}\{W(x, y, f)\}$ e $\mathcal{F}\{V(y, f)\}$. A função $W(x, y)$ é uma gaussiana, portanto um filtro passa-baixa, enquanto que $V(y)$ é uma cosseno de frequência f , portanto sua resposta em frequência são dois impulsos simétricos com relação a origem nos pontos f . A Figura 4.25 apresenta os gráficos de $\mathcal{F}\{W(x, y)\}$ e $\mathcal{F}\{V(y, f)\}$.

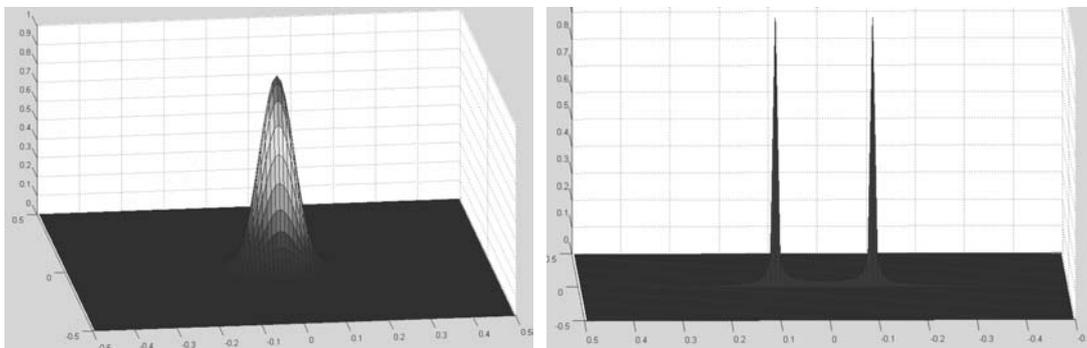


Figura 4.25 – À esquerda é exibida a transformada de Fourier de $W(x, y)$ que consiste em um filtro passa-baixa. À direita está a transformada de $V(y, f)$ que é um cosseno de frequência $f = 0.1$ (neste exemplo), que consiste em dois impulsos simétricos com distância $f = 0.1$ da origem.

Portanto, como a transformada de Fourier de $G(x, y)$ é a convolução de $\mathcal{F}\{W(x, y)\}$ com $\mathcal{F}\{V(x, y)\}$, o resultado é um filtro passa-banda que realça as senóides com frequências em torno de f e suprime os ruídos destas senóides. A Figura 4.26 exhibe o gráfico de $\mathcal{F}\{G(x, y)\}$.

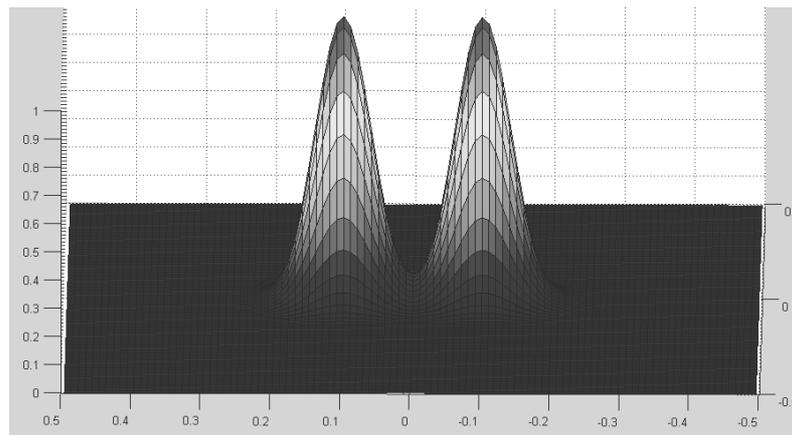


Figura 4.26 – Gráfico da transformada de Fourier de $G(x,y,f)$, com frequência $f = 0.1$. O resultado é um filtro passa-banda com auge da banda passante nos pontos 0.1 e -0.1 (valor da frequência).

Fragmentos pequenos de impressões digitais se assemelham a senóides (JAIN; PANKANTI, 1997), a Figura 4.27 ilustra esta afirmação.

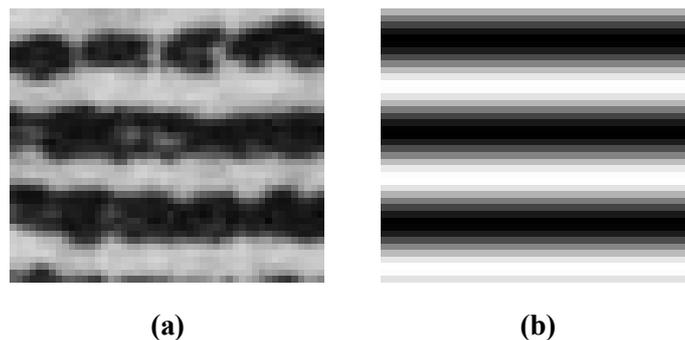


Figura 4.27 – À esquerda é exibido um fragmento de uma impressão digital, observe como é semelhante à senoide da direita.

Aplicando-se o filtro de Gabor com frequência $f = 1/14$ na Figura 4.27(a) obtém-se a imagem exibida na Figura 4.28(b).

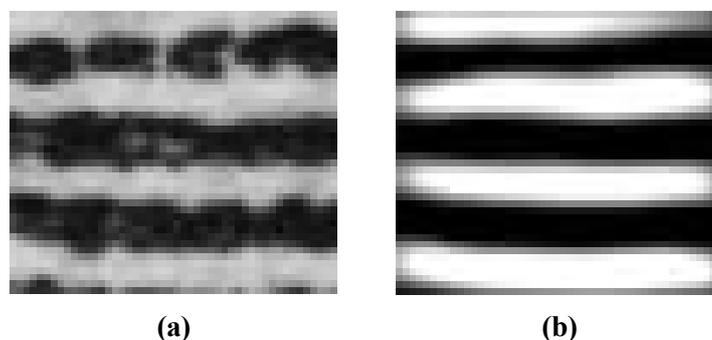


Fig. 4.28 – (a) Imagem de um fragmento de impressão digital. (b) Imagem filtrada por um filtro de Gabor com frequência $f = 1/14$. As linhas da digital foram realçadas e as suas imperfeições foram suprimidas.

Da Figura 4.28(b) pode-se observar uma melhoria na qualidade do contraste da imagem da impressão digital e as pequenas imperfeições das bordas das linhas, assim como os ruídos, foram suprimidos. Portanto, o filtro de Gabor resulta na melhoria da qualidade de imagens de impressões digitais.

Porém, se a imagem da Figura 4.27(a) for filtrada com um filtro de Gabor com frequência $f = 1/5$, a imagem tem suas linhas descaracterizadas. A Figura 4.29 apresenta este resultado.

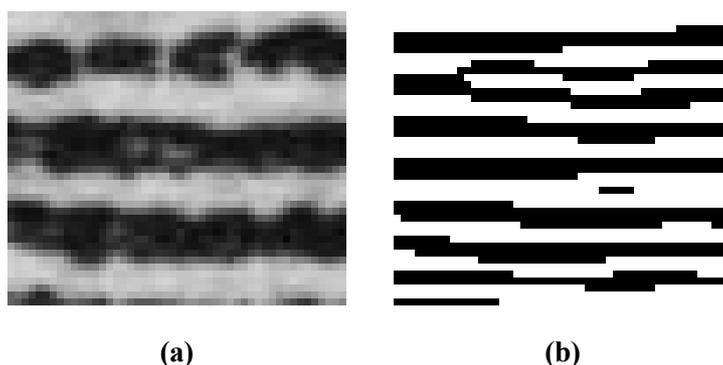


Figura 4.29 – (a) Fragmento de uma impressão digital. (b) Imagem filtrada com o filtro de Gabor com frequência $f = 1/5$. Note que as linhas da impressão foram descaracterizadas, mostrando a importância do parâmetro f .

Fica claro da Figura 4.29 que o parâmetro f é de extrema importância. O valor ideal para este parâmetro é a frequência da senóide a ser realçada, no caso da impressão digital, o valor ideal para f é o inverso do dobro da largura de sua linha. Na imagem da Figura 4.25(a) a linha possui largura aproximada de 7 pixels, portanto, $f = \frac{1}{2 \cdot 7} = \frac{1}{14} = 0.0714 \text{ ciclos / pixel}$ é o valor ideal para filtrar esta imagem. A equação 4.8 apresenta o cálculo da frequência f .

$$f = \frac{1}{2 \cdot b} \text{ ciclos / pixel} \quad (\text{eq. 4.8})$$

Onde b é a largura em pixels das linhas da impressão digital.

Portanto, uma dificuldade da aplicação do filtro de Gabor é a correta estimativa da largura das linhas, que não é uma tarefa fácil principalmente em imagens ruidosas.

A aplicação do filtro de Gabor apresenta ainda um outro problema. Até o momento foram utilizados como exemplo apenas imagens com senóides que oscilam verticalmente (ao longo do eixo y). Caso o filtro seja aplicado em imagens senoidais

com outra orientação, o resultado obtido também não é satisfatório. A Figura 4.30 apresenta a imagem da Figura 4.27(a) com uma rotação de 90^0 , assemelhando-se a uma senóide que oscila horizontalmente (ao longo do eixo x), filtrada com o filtro de Gabor com frequência $f = 1/14$.

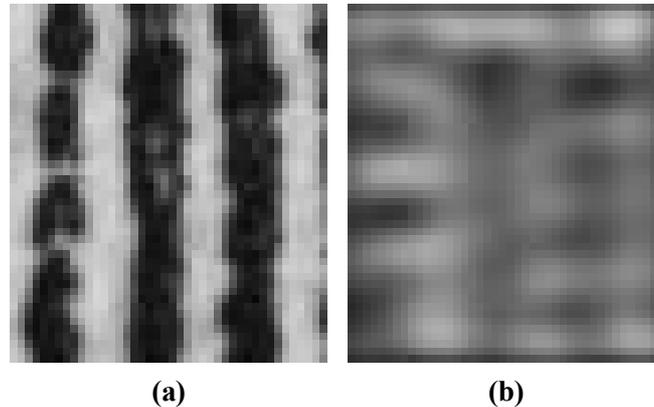


Figura 4.30 – (a) Fragmento de uma impressão digital onde as linhas oscilam horizontalmente. (b) Imagem resultante da filtragem de (a) com o filtro de Gabor de frequência $f = 1/14$. As linhas da imagem foram descaracterizadas.

Da Figura 4.30 se conclui que é necessário que o filtro de Gabor seja, também, função da direção das linhas. Seja θ o ângulo que as linhas fazem com o eixo x , a Figura 4.31 ilustra esta definição. É necessário que o filtro de Gabor da equação 4.6 seja rotacionado de θ , como apresentado na equação 4.9.

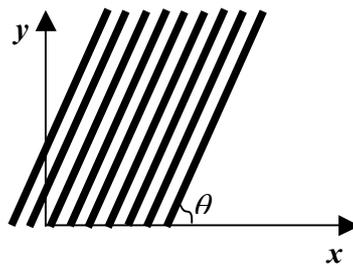


Figura 4.31 – Linhas de uma impressão digital e o ângulo θ que elas fazem com eixo x .

$$G(x, y, f) = \exp\left(-0.5 \cdot \left(\frac{x_r^2}{gx^2} + \frac{y_r^2}{gy^2}\right)\right) \cdot \cos(2 \cdot \pi \cdot f \cdot y) \quad (\text{eq. 4.9})$$

onde

$$x_r = x \cdot \cos(\theta) - y \cdot \sin(\theta)$$

$$y_r = y \cdot \cos(\theta) + x \cdot \sin(\theta)$$

Aplicando-se o filtro da eq. 4.9 com $f = \frac{1}{14}$ e $\theta = \frac{\pi}{2}$ na imagem da Figura 4.30

(a) obtém-se a imagem da Figura 4.32(b).

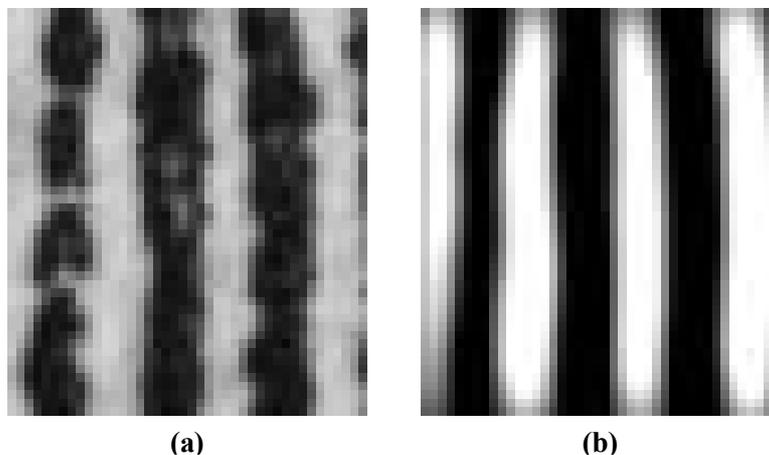


Figura 4.32 – (a) Imagem de um fragmento de impressão digital cujas linhas se assemelham a uma senóide que oscila ao longo do eixo x . (b) Aplicação do filtro de Gabor com $f = 1/14$ e $\theta = 90^\circ$.

Em uma imagem de impressão digital, as suas linhas possuem direções e larguras variadas ao longo da imagem. Portanto, a aplicação do filtro de Gabor em uma imagem de impressão digital consiste em um processo complexo, em que para cada pixel da imagem é necessário computar a direção e a largura das linhas próximas ao pixel, aplicando-se a convolução com a máscara correta dada pela eq. 4.9.

Em (HONG, WAN, JAIN, 1998) os autores propõem um método para se aplicar o filtro de Gabor dividindo a imagem em imagens menores. E para cada uma dessas sub-imagens é feita uma estimativa da direção e largura das linhas. Depois, cada pixel é percorrido e são utilizadas a largura e direção das regiões mais próximas do pixel para se calcular a matriz de convolução correta.

A estimativa de direção θ das linhas é feita utilizando-se os gradientes dos tons de cinza da região. A estimativa da largura da linha é feita projetando-se os pixels na direção θ obtendo-se a *x-signature*, nome dado pelos autores. A Figura 4.33 exhibe o cálculo da *x-signature*.

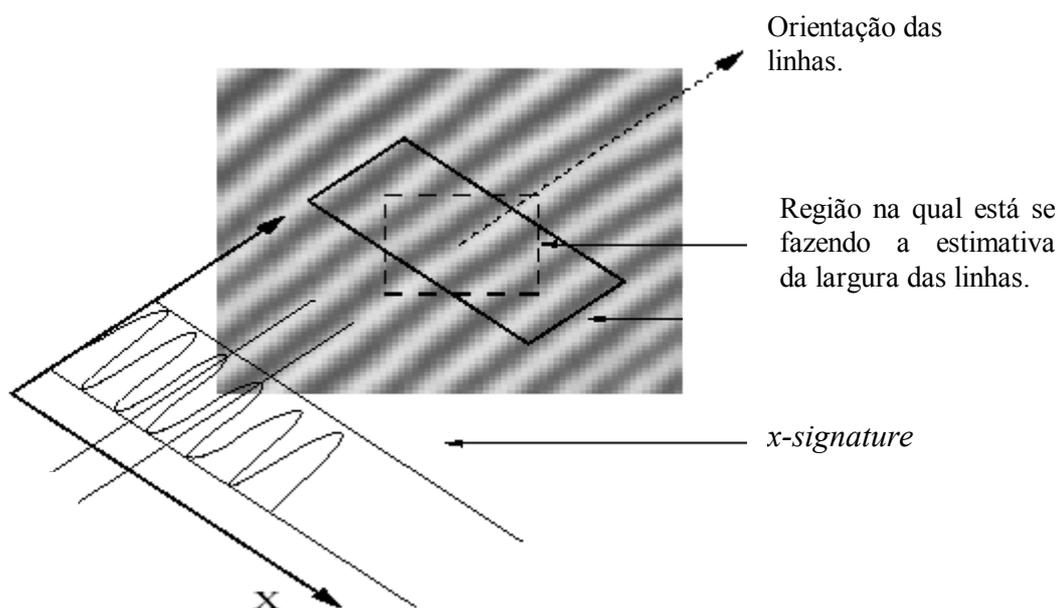


Figura 4.33 – Como o método proposto em (HONG, WAN, JAIN, 1998) obtém a *x-signature* que consiste na projeção dos tons de cinza ao longo da orientação da linha. A *x-signature* é utilizada para se estimar a largura das linhas da impressão digital.

A *x-signature* tem a forma semelhante a uma função senoidal, pois consiste na projeção das linhas na direção θ . Para se obter uma estimativa da largura das linhas basta estimar a frequência da *x-signature* calculando-se a distância entre dois de seus picos. Esta estimativa nem sempre é simples, pois muitas vezes a imagem possui ruídos que dificultam o processo.

Desta forma, tanto a direção quanto a frequência das linhas pode ser estimado para cada pixel da imagem. Basta então aplicar a matriz de convolução correta utilizando-se a equação 4.9. No entanto, este processo é muito caro computacionalmente, pois computar a máscara de convolução por pixel exigiria muito tempo de processamento. Por essa razão, os autores propuseram a utilização de um banco de filtros de Gabor, que consiste em um conjunto de matrizes de convolução pré-computadas para várias orientações e frequências diferentes. Desta forma, cada pixel é convolvido com a máscara de convolução pré-computada que possuir ângulo e frequência mais próximos de suas estimativas.

Apesar do filtro de Gabor aumentar o contraste das senóides de determinada frequência, os autores de (HONG, WAN, JAIN, 1998) propõem que a imagem passe

por um filtro de realce antes de se aplicar o filtro de Gabor. Para exibir o realce que o filtro de Gabor traz às imagens, foram feitos testes em algumas imagens de impressões digitais e aplicado o filtro proposto em (HONG, WAN, JAIN, 1998). As imagens, no entanto, foram realçadas utilizando-se o algoritmo de equalização local interpolada descrito na Seção 4.1. As figuras 4.34 e 4.35 exibem as imagens utilizadas para os testes, as imagens após a equalização local interpolada e as imagens após a aplicação do filtro de Gabor.

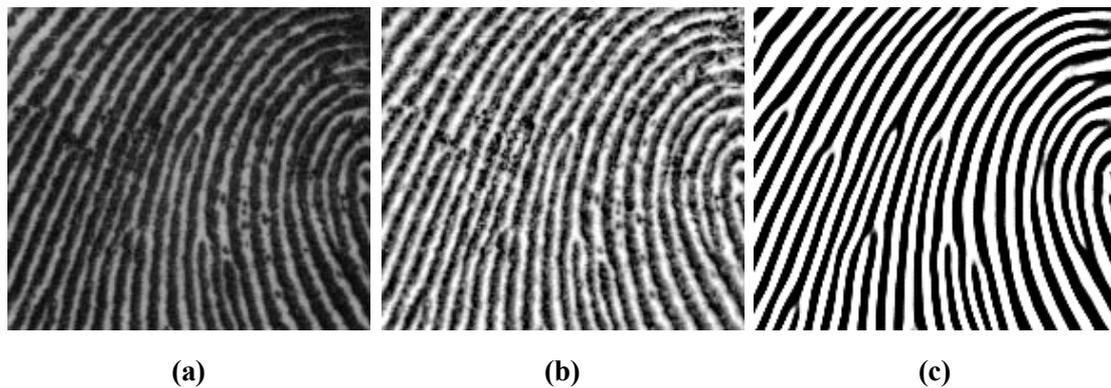


Figura 4.34 – (a) Um fragmento de impressão digital. (b) Imagem de (a) equalizada com o algoritmo da seção 4.1. (c) Resultado do filtro de Gabor proposto em (HONG, WAN, JAIN, 1998) aplicado à imagem de (b).

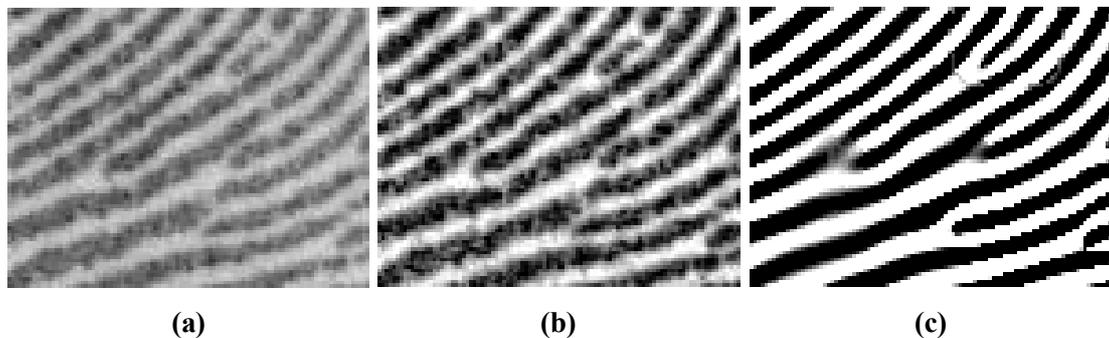


Figura 4.35 – (a) Um fragmento de impressão digital. (b) Imagem de (a) equalizada com o algoritmo da seção 4.1. (c) Resultado do filtro de Gabor proposto em (HONG, WAN, JAIN, 1998) aplicado à imagem de (b).

Em (LEUNG, ENGELER, FRANK, 1990) é exibido um filtro de Gabor complexo onde a parte real do filtro é dada pela equação 4.9 e a parte imaginária difere da real apenas pela troca da função cosseno pelo seno. A equação 4.10 exhibe a fórmula do filtro de Gabor complexo.

$$\text{Seja } G_r(x, y, f, \theta) = G(x, y, f, \theta) = \exp\left(-0.5 \cdot \left(\frac{x_r^2}{gx^2} + \frac{y_r^2}{gy^2}\right)\right) \cdot \cos(2 \cdot \pi \cdot f \cdot y_r^2)$$

$$G_i(x, y, f, \theta) = \exp\left(-0.5 \cdot \left(\frac{x_r^2}{gx^2} + \frac{y_r^2}{gy^2}\right)\right) \cdot \text{sen}(2 \cdot \pi \cdot f \cdot y_r^2)$$

$$x_r = x \cdot \cos(\theta) - y \cdot \text{sen}(\theta)$$

$$y_r = y \cdot \cos(\theta) + x \cdot \text{sen}(\theta)$$

$$j = \sqrt{-1}$$

$$G_c(x, y, f, \theta) = G_r(x, y, f, \theta) + j \cdot G_i(x, y, f, \theta) \quad (\text{eq. 4.10})$$

Das equações acima se tem que $G_r(x, y, f, \theta)$, $G_i(x, y, f, \theta) \in \mathcal{R}$ e $G_c(x, y, f, \theta) \in \mathcal{C}$. O filtro G_c possui uma propriedade muito interessante quando aplicado a imagens de impressões digitais. No entanto, para explicar melhor esta propriedade é necessário estudar algumas propriedades de G_r e G_i como filtros independentes.

O filtro G_r é o filtro abordado desde o início desta seção, porém existem duas propriedades deste filtro que devem ser salientadas. A primeira diz respeito a sua Transformada de Fourier, $\mathcal{F}\{G_r\}$, que como visto é o resultado da convolução das transformadas de uma gaussiana com a de uma função cosseno. Como a função gaussiana e a cosseno são simétricas em relação à origem, isso garante que a G_r também o é e, portanto, a sua Transformada de Fourier é real, ou seja, $\mathcal{F}\{G_r\} \in \mathcal{R}$. Isso implica que o filtro G_r não altera as fases das senóides que compõem o sinal, modificando somente as suas amplitudes.

A outra propriedade de G_r é a sua simetria com relação ao eixo ortogonal a direção θ . Para verificar esta propriedade basta observar que para $\theta = 0$, tem-se que $G_r(x, y, f, 0) = G_r(-x, y, f, 0)$, ou seja, para $\theta = 0$ o filtro G_r é simétrico em relação ao eixo y que por sua vez é ortogonal à direção θ . A Figura 4.36 ilustra esta simetria.

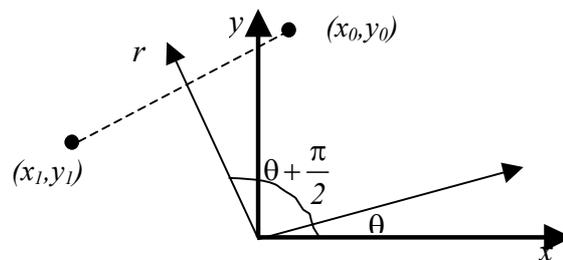


Figura 4.36 – O eixo r é ortogonal à direção θ do filtro. Os pontos (x_0, y_0) e (x_1, y_1) são simétricos a r , portanto $G_r(x_0, y_0, f, \theta) = G_r(x_1, y_1, f, \theta)$.

O filtro G_i também possui a propriedade de ser simétrica com relação ao eixo ortogonal a sua direção, basta observar que $G_i(x,y,f,0) = G_i(-x,y,f,0)$.

A transformada de Fourier de G_i possui uma propriedade interessante. Semelhante ao filtro G_r , $\mathcal{F}\{G_i\}$ é a convolução da transformada de uma gaussiana com a transformada de uma função seno. Apesar da transformada da gaussiana ser real e simétrica, a transformada do seno é imaginária, ou seja, a sua parte real é nula. Contudo, a transformada do seno também são dois impulsos simétricos com relação à origem, portanto $|\mathcal{F}\{G_i\}| = |\mathcal{F}\{G_r\}|$, donde G_i é também um filtro passa-banda com a mesma banda passante de G_r . Contudo, G_i translada as fases das senóides em 90° , ou seja, as senóides são deslocadas de $\frac{1}{4}$ de seu período, já que o período de um seno ou cosseno é de 360° . Para ilustrar esta situação, o filtro G_i é aplicado na imagem da Figura 4.27(a), com $f = 1/14$ e o resultado é exibido na Figura 4.37. Observe que a imagem sofreu um deslocamento da metade da largura das linhas, ou seja, aproximadamente 3 pixels.

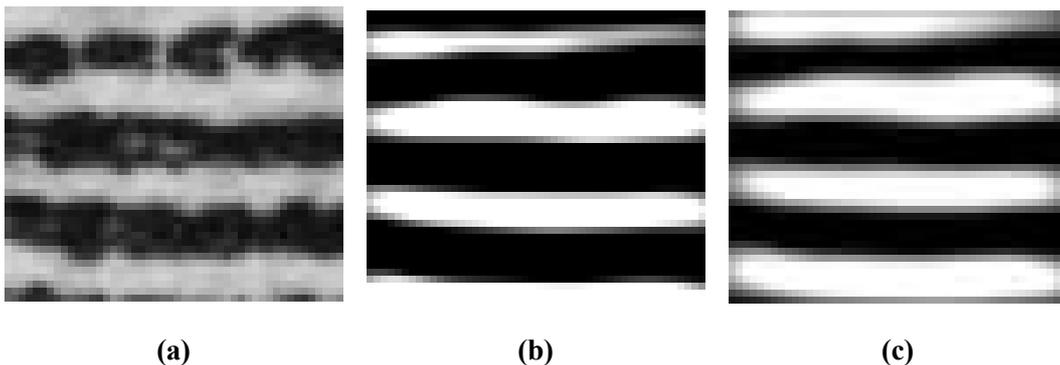


Figura 4.37 – (a) Imagem de um fragmento de impressão digital. (b) Imagem após a aplicação do filtro G_i , observe como a fase da senóide foi modificada. (c) Imagem após a aplicação do filtro G_r , neste caso o filtro não modificou a fase da senóide.

Convoluir uma imagem com o filtro complexo G_c resulta em um sinal complexo, onde a parte real é igual a convoluir a imagem com G_r e a parte imaginária igual a convolução com G_i . No entanto, se uma imagem for construída a partir do valor absoluto da convolução, mapeando-se o zero como sendo o preto e o 255 como o valor absoluto mais alto, a imagem resultante será semelhante a da Figura 4.38, onde os pixels próximos aos centros das linhas ficam um pouco mais escuros do que no restante da imagem.

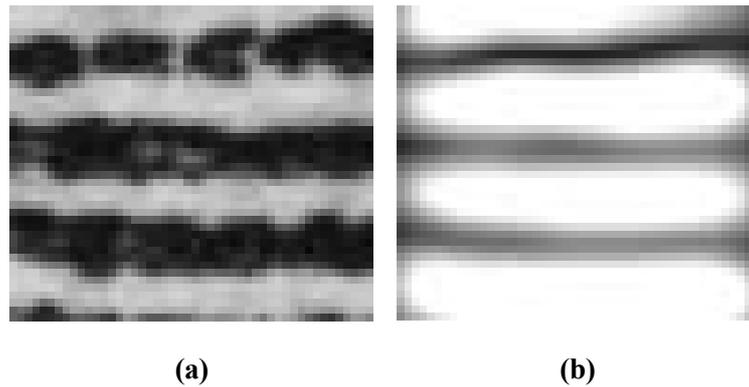


Figura 4.38 – (a) Fragmento de uma impressão digital. (b) Imagem obtida através do módulo da convolução de (a) com o filtro G_c , mapeando-se o valor 0 com o tom preto e o valor mais alto com o tom de cinza branco.

Isso ocorre pela seguinte razão: ao se convoluir uma senóide com o filtro G_c a parte real é uma senóide realçada com a mesma fase da senóide original. Enquanto que a parte imaginária é idêntica à parte real exceto por um deslocamento de $\frac{1}{4}$ de seu período. Como o deslocamento entre os dois é pequeno, os seus vales (centro das linhas) são próximos, e por isso a soma de seus quadrados fica pequena próxima dessa região. A Figura 4.39 exibe o que foi explicado.

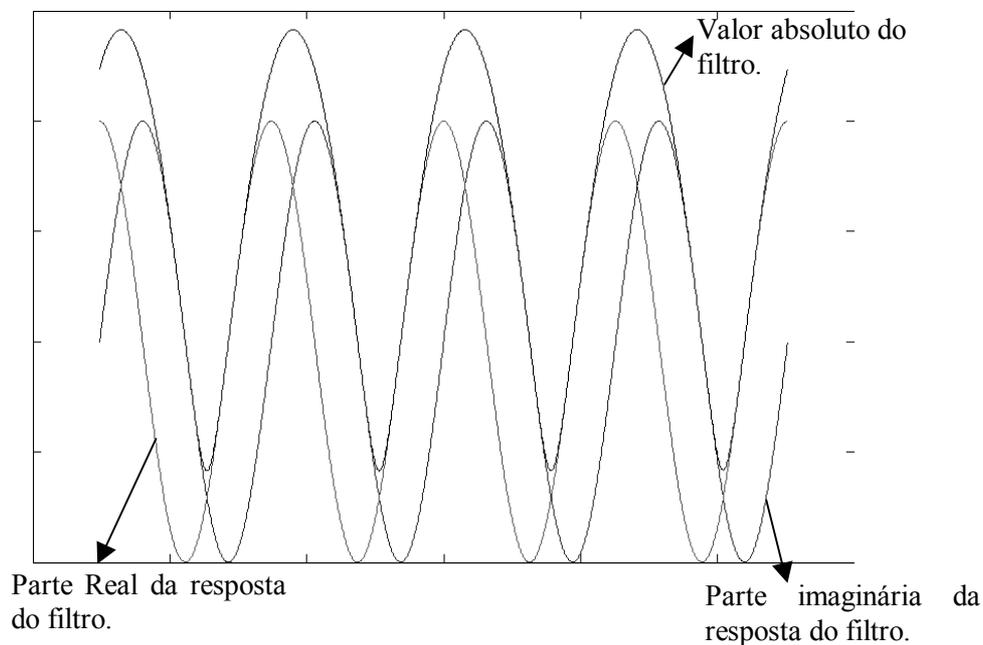


Figura 4.39 – Sinal filtrado com o gabor complexo. A parte real e imaginária são idênticas a não ser por um deslocamento de $\frac{1}{4}$ de seu período. O valor absoluto, dado pela raiz da soma dos quadrados da parte real e imaginária, assume valores mais baixos próximo ao vale das duas funções.

A propriedade mais importante do filtro de Gabor complexo, salientada em (LEUNG, ENGELER, FRANK, 1990), é a sua sensibilidade a mudanças de fase nas senóides. Para explicar melhor esta propriedade considere a Figura 4.40, que consiste em uma imagem onde a metade da esquerda é uma senóide, e a metade da direita é uma senóide com igual amplitude, porém com a fase deslocada em π radianos, ou seja, de $\frac{1}{2}$ período.

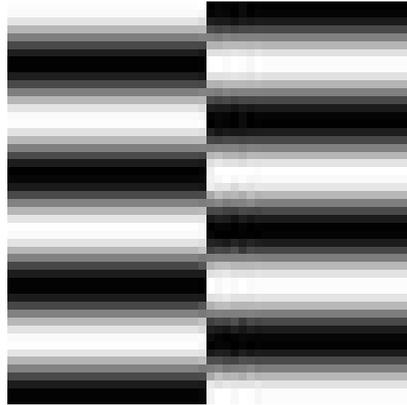


Figura 4.40 – Imagem em que a metade da esquerda consiste em uma senóide e a metade da direita uma senóide igual com fase deslocada de π radianos.

Aplicando-se o filtro G_c na imagem da Figura 4.40 e criando uma imagem com o módulo da resposta, obtém-se a imagem da Figura 4.41.

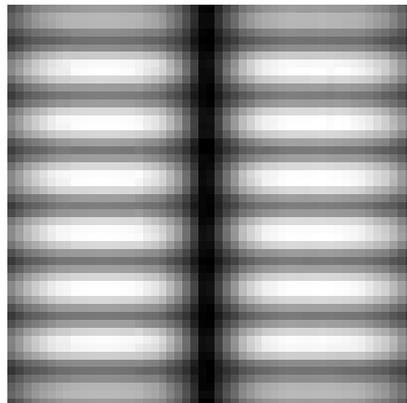


Figura 4.41 – Imagem obtida através do valor absoluto da imagem da Figura 4.40 aplicada ao filtro G_c .

Na Figura 4.41 observa-se que os pixels que se encontram horizontalmente no centro da imagem estão próximos do tom preto, indicando que o módulo da convolução com o filtro assume um valor próximo de zero. Isso ocorre por causa das propriedades de simetrias explicadas anteriormente. Neste exemplo, o filtro utilizado tem direção

$\theta = 0$, portanto o filtro é simétrico com relação ao eixo vertical (eixo y). Observando-se a imagem da Figura 4.40, a metade da esquerda é igual à metade da direita invertendo-se os valores de tons de cinza, ou seja, a imagem é anti-simétrica com relação ao eixo y . Como o filtro é simétrico com relação ao eixo y , a convolução nos pontos centrais irá tender a zero, tanto na parte real como imaginária.

Esta propriedade é muito interessante, porque a imagem em torno de uma minúcia, em uma impressão digital, geralmente está associada a uma mudança de fase. Observe esta afirmação na Figura 4.42 (LEUNG, ENGELER, FRANK, 1990).

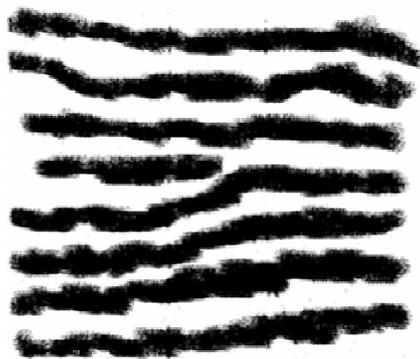


Figura 4.42 – Imagem de um fragmento de impressão digital com um fim-de-linha no centro (LEUNG, ENGELER, FRANK, 1990). O lado direito e esquerdo da minúcia são parecidos com senóides de mesma frequência, mas com fases diferentes.

Aplicando-se o filtro de Gabor complexo e analisando o seu valor absoluto, é obtida a imagem da Figura 4.43. Observe que onde a minúcia se encontra aparece uma região muito escura.



Figura 4.43 – Imagem da Figura 4.42 após a aplicação do filtro de Gabor complexo com orientação de zero grau. Observe que na região do fim-de-linha a imagem fica mais escura.

Se a minúcia fosse uma bifurcação ocorreria o mesmo efeito já que uma bifurcação é igual a um fim-de-linha com os tons de cinza invertidos. Dessa forma, o filtro de Gabor também pode ser utilizado para a localização de minúcias.

O texto desta seção teve como objetivo exibir as vantagens do filtro de Gabor, tanto para uso como um filtro que realça a qualidade da imagem, como um filtro que pode ser utilizado para localizar minúcias. Apesar destas vantagens, o filtro de Gabor tem algumas desvantagens, e uma delas é que o filtro pode criar falsos fins-de-linha ou bifurcações, pois ele pode acabar unindo ou desunindo linhas na imagem, além de ser um filtro caro computacionalmente.

4.4 Proposta de Aproximação do Filtro de Gabor através de uma Rede Neural

Como visto na seção anterior, o filtro de Gabor apresenta vantagens quando utilizado para realçar imagens de impressões digitais ou para auxiliar na detecção de minúcias, porém é um filtro caro computacionalmente.

Uma das razões do filtro de Gabor possuir um baixo desempenho em termos de custo computacional se dá pelo fato do filtro utilizar uma vizinhança razoavelmente grande, por exemplo, 11x11 pixels. Porém, para se obter um resultado com melhor qualidade é necessário utilizar uma região maior do que 11 pixels.

Nesta seção é proposto e investigado o uso de uma rede neural para aproximar a saída do filtro de Gabor utilizando uma vizinhança de 13x13 pixels. A esperança é que as camadas não-lineares da rede compensem a utilização de uma pequena vizinhança. O método consiste basicamente em percorrer a imagem pixel a pixel, estimar a direção local das linhas e extrair uma projeção da imagem ao longo desta direção, igual a *x-signature* proposta em (HONG, WAN, JAIN, 1998). Depois utilizar esta projeção como vetor de entrada para uma rede neural que deve estimar qual seria a resposta, para o pixel corrente, da convolução de um filtro de Gabor na mesma direção. Outra vantagem de se utilizar este método é que não é necessário o cálculo de estimativa de frequência das linhas. Esta proposta toma por base uma idéia lançada inicialmente por Daugman (DAUGMAN, 1988) na qual uma rede neural é utilizada para aproximar o filtro de Gabor. As estratégias de construção dos modelos neurais são diferentes e, além disto,

naquele trabalho o filtro de Gabor é utilizado no contexto de análise e compressão de imagens enquanto neste trabalho o contexto é extração de minúcias e melhoria da qualidade e do contraste das linhas de uma impressão digital.

As próximas seções descrevem o método em detalhes, descrevendo a criação da base de treinamento e a extração do vetor de características, exibindo os resultados obtidos comparando-os com imagens de filtros de Gabor utilizando vizinhanças de 13x13 e 17x17 pixels, e fazendo uma comparação do tempo de processamento.

4.4.1 Treinamento

A base de treinamento para a rede neural é constituída de várias funções senoidais, criadas sinteticamente, com fase e período variados, e a introdução de um ruído pseudo-aleatório. As senóides são bidimensionais e oscilam ao longo do eixo y . A seguir é exibido como a fase, período e ruído foram utilizados na criação das senóides:

- a fase varia dentro do intervalo $[0, 2\pi)$, discretizado em 40 intervalos iguais;
- o período assume os valores inteiros no intervalo $[6, 20]$, portanto, assumindo 15 valores possíveis;
- depois de criada a imagem da senóide com uma determinada fase e período, o ruído pseudo-aleatório consiste na soma pixel a pixel de um valor que oscila aleatoriamente entre $[-L, L]$. Os valores que L assume estão no intervalo $[0, 96]$ dividido em 7 intervalos uniformes. Cabe ressaltar que quando L for zero, significa que nenhum ruído é adicionado na imagem.

Os valores para os intervalos descritos acima foram obtidos de forma empírica, através de vários testes durante o treinamento de várias configurações de rede, retendo-se os valores que corresponderam à melhor delas.

O pseudocódigo a seguir simplifica como se dá a criação da base de treinamento:

Algoritmo Criar_Base_Treinamento

Início

Para α variando no intervalo $[0, 2\pi)$ faça

Para T variando no intervalo $[6, 20]$ faça

Para L variando no intervalo $[0, 96]$ faça

Crie uma senóide S com período T e fase α ;
Adicione a S um ruído pseudo-aleatório oscilando entre $-L$ e L ;
Adicione S à base de treinamento;

Fim para

Fim para

Fim para

Fim

Como a fase assume 40 valores, o período 15 e o ruído 7, a base de treinamento é constituída de $40 \times 15 \times 7 = 4200$ imagens. A Figura 4.44 exhibe 3 senóides, com fase ruído e período diferentes. Cada imagem possui 13×13 pixels.

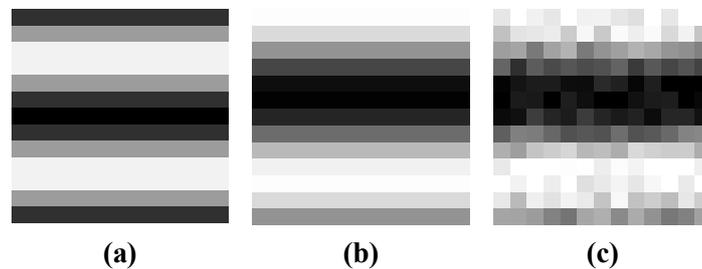


Figura 4.44 – (a) Uma senóide com período 7, fase 0 e sem ruído. (b) Uma senóide sem ruído, com fase 45° e período 10. (c) Uma senóide igual a (b) com ruído oscilando entre -32 e 32.

O vetor de entrada da rede não são todos os pixels da imagem, mas um vetor de 13 posições composto pelas médias de cada linha da imagem. A saída desejada da rede é obtida filtrando-se cada imagem com o filtro de Gabor complexo G_c , e a rede deve gerar como saída o valor real e imaginário do pixel central da convolução.

A rede neural escolhida é do tipo MLP, possuindo uma camada escondida com 3 neurônios e 2 neurônios na camada de saída, um para aproximar a parte real e outro a imaginária do filtro. A função de propagação de todos os neurônios é a tangente hiperbólica.

Neste momento cabe fazer duas observações:

- o filtro de Gabor tem suas saídas variando no intervalo de $[0 \text{ a } 255]$, porém, para o treinamento, estes valores foram mapeados no intervalo de $[-1, 1]$;
- cada posição do vetor de entrada é dividido por 255 para garantir que os valores de entrada oscilem dentro do intervalo $[0, 1]$.

A rede foi treinada com o algoritmo *RProp (Resilient Backpropagation)*, com o objetivo de atingir um erro quadrático médio de no máximo 0.001. O treinamento atingiu um erro quadrático médio de 0.0018, não atingindo o objetivo, em 350 ciclos de treinamento.

4.4.2 Implementação do filtro

Após o treinamento da rede, a implementação do filtro se dá da seguinte forma:

1º passo: Aplicar a equalização local interpolada, descrita na Seção 4.1, na imagem de entrada.

2º passo: Estimar a orientação das linhas da impressão digital dividindo-se a imagem em vários blocos de 32x32 pixels, com superposição de 16 pixels.

3º passo: Para cada pixel da imagem repita os passos 4 e 5.

4º passo: Crie janela de 13x13 pixels centralizada no pixel corrente e a gire utilizando o ângulo das direções das linhas estimado no passo 2. Crie um vetor de 13 posições, onde cada posição possui a média de uma das 13 linhas da janela e divida cada posição por 255.

5º passo: Utilizar o vetor obtido no passo anterior como entrada para a rede e obter sua saída. O neurônio responsável pela parte real do filtro realça a qualidade da imagem, sendo que é necessário fazer o mapeamento de -1 a 1 para 0 e 255 respectivamente.

Para que o 4º passo seja executado de forma eficiente, é feita uma pré-computação de rotações para 16 ângulos diferentes. Depois, é utilizada a rotação pré-computada mais próxima da orientação local em torno do pixel corrente.

4.4.3 Experimentos

A Figura 4.45 exibe uma imagem que foi filtrada utilizando-se o método descrito na seção anterior e a compara com imagens geradas pelo filtro de Gabor de 17x17 pixels e de 13x13 pixels. Observe como as linhas da impressão digital foram realçadas.

Das imagens da Figura 4.45 pode-se observar que, apesar das imagens serem bem parecidas, a imagem gerada pelo método proposto possui uma qualidade um pouco superior ao da imagem gerada pelo filtro de 13x13 pixels e bem próxima ao do filtro de 17x17 pixels.

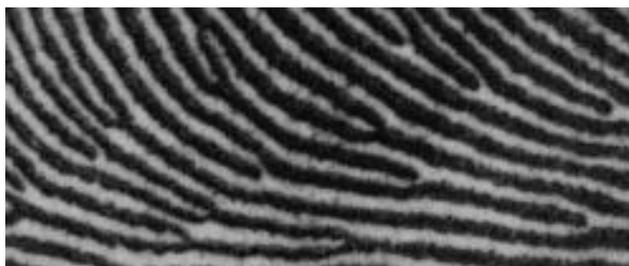


Imagem original



Imagem filtrada com o método proposto na seção 4.3.2



Imagem filtrada com um filtro de Gabor com máscara de 17x17 pixels.

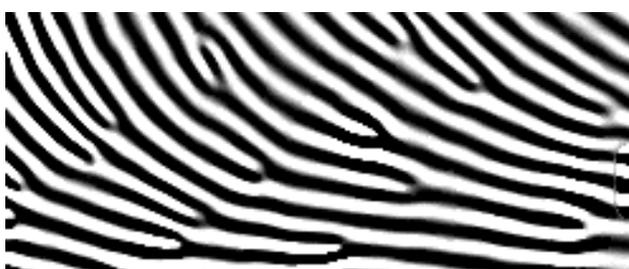


Imagem filtrada com um filtro de Gabor com máscara de 13x13 pixels.

Figura 4.45 – De cima para baixo estão, a imagem original, a imagem filtrada com o método proposto, a imagem filtrada com o filtro convencional de 17x17 pixels e a imagem filtrada com 13x13 pixels. As qualidades das 3 imagens são bem parecidas, porém a imagem da rede é um pouco melhor do que da imagem gerada pelo filtro de 13x13 pixels e muito próxima a de 17x17 pixels.

As figuras 4.46 e 4.47 exibem outros fragmentos de imagens filtradas com o método proposto nesta seção.

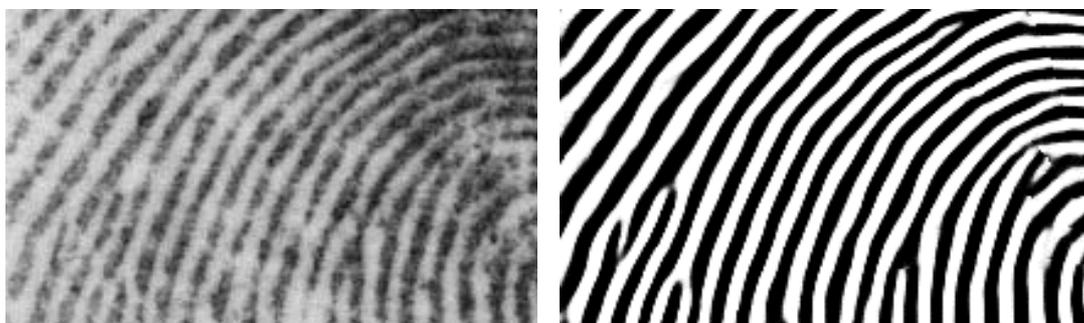


Figura 4.46 – Fragmento de impressão digital com seu respectivo filtro de Gabor utilizando o método proposto nesta seção.



Figura 4.47 – Fragmento de impressão digital com seu respectivo filtro de Gabor utilizando o método proposto nesta seção.

Para finalizar os experimentos do filtro de Gabor neural é necessário fazer a análise do filtro complexo, pois as imagens exibidas até o momento só utilizaram o neurônio da rede responsável pela parte real do filtro. O filtro complexo, como visto na

Seção 4.2 pode ser utilizado para auxiliar na detecção das minúcias. Na Figura 4.48 é exibida uma imagem obtida utilizando o método proposto da seguinte forma: cada pixel recebe o somatório dos quadrados das duas saídas da rede dividido por 2 e multiplicado por 255 como valor de luminância. A equação 4.11 exibe este método.

$$pixel(x, y) = 255 \cdot \frac{n_0^2 + n_1^2}{2} \quad (eq. 4.11)$$

Onde: n_0 e n_1 são os neurônios de saída da rede no pixel (x, y) .

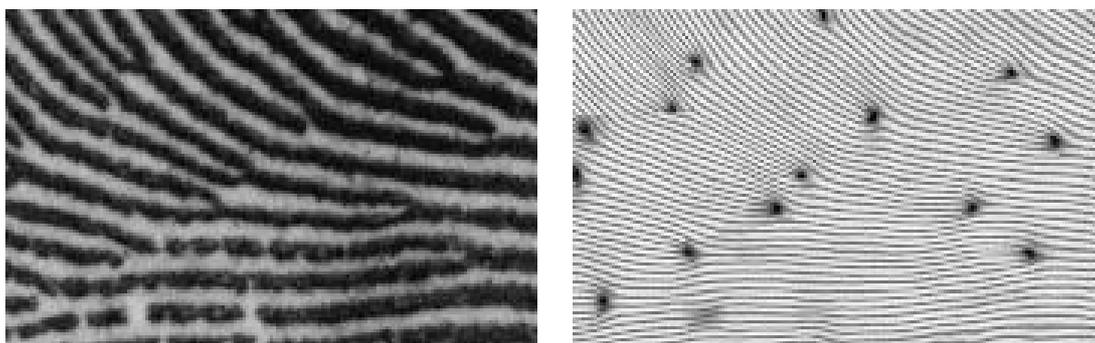


Figura 4.48 – A imagem da esquerda é um fragmento de impressão digital, e a imagem da direita é a imagem filtrada com o método proposto utilizando a equação 4.11. Observe que as regiões próximas de minúcias ficam mais escuras.

Da Figura 4.48 pode-se observar que as regiões próximas a fins-de-linha e bifurcações ficam mais escuras. Portanto, a rede conseguiu simular de forma eficiente o filtro de Gabor complexo e real mantendo suas propriedades.

4.4.4 Análise dos resultados e Conclusão

Na seção anterior, pôde-se observar que o filtro de Gabor neural aproxima bem o filtro de Gabor tradicional e que, apesar da rede utilizar uma vizinhança de 13 pixels, o resultado final da filtragem se assemelha mais com o filtro de Gabor tradicional de 17 pixels de vizinhança do que com o de 13 pixels. Ou seja, houve um ganho, em termos de qualidade, ao se utilizar a rede neural. Resta, no entanto, fazer uma análise dos tempos computacionais entre os filtros de Gabor tradicional e neural.

Os filtros foram testados em um AthlonXP 2000+ de 1.7 GHz e os seus respectivos tempos de processamento, em uma imagem de 800x768 pixels, são exibidos na Tabela 4.1.

Método	Tempo de processamento	Tempo percentual comparado ao tempo do método proposto
Neural	2,08 segundos	100%
Gabor de 13x13 pixels	2,53 segundos	122%
Gabor de 17x17 pixels	3,64 segundos	175%

Tabela 4.1 – Comparação do tempo de processamento entre o método proposto e os filtros de Gabor com 13x13 e 17x17 pixels.

Apesar dos tempos absolutos, exibidos na tabela anterior, serem importantes, estes valores são muito dependentes da implementação dos filtros e do computador utilizado. Portanto, para que análise de tempo computacional seja mais robusta, foi escolhido fazer a contagem do número de multiplicações e somas de números de ponto flutuante utilizados em cada filtro.

Seja $NMGT$ o número de multiplicações utilizadas para filtrar uma imagem através do filtro de Gabor Tradicional, implementado por uma operação de convolução. Este número é dependente do tamanho k da máscara de convolução utilizada e do tamanho da imagem. Para simplificar os cálculos, assume-se que a imagem I , a ser filtrada, é quadrada com dimensões n , ou seja, I possui n linhas e n colunas. Desta forma, $NMGT$ é dado pela equação 4.12.

$$NMGT = n^2 \cdot k^2 \quad (eq. 4.12)$$

O número de somas de números de ponto flutuante, utilizadas pelo mesmo filtro, será chamado de $NSGT$ e é igual ao número de multiplicações, ou seja, $NSGT = NMGT$.

Para se aplicar o filtro de Gabor complexo é necessária a aplicação de duas operações de convolução, uma para parte real e outra para a imaginária. Portanto, o filtro complexo utiliza o dobro de somas e multiplicações do filtro de Gabor simples.

Chamando-se, respectivamente, de $NMGTC$ e $NSGTC$ o número de multiplicações e somas do filtro de Gabor tradicional complexo, tem-se que:

$$NMGTC = NSGTC = 2 \times NMGT$$

O número de somas e multiplicações utilizadas no filtro de Gabor neural, deve-se levar em conta não somente o tamanho da imagem e da máscara de convolução mas também o número de neurônios utilizados na rede. Serão chamados, respectivamente, de $NMGN$ e $NSGN$ ao número de multiplicações e somas utilizadas em uma operação de filtragem através do Gabor neural. O valor de $NMGN$ é dado pela equação 4.13.

$$NMGN = n^2 \cdot (k \cdot m + 2 \cdot m) \quad (eq. 4.13)$$

Onde m é o número de neurônios utilizados na camada escondida.

O termo $(k \cdot m + 2 \cdot m)$ da equação 4.13 representa as k multiplicações executadas por cada um dos m neurônios da camada escondida mais as m multiplicações de cada um dos dois neurônios da camada de saída.

O número de somas é praticamente igual a $NMGN$ adicionado ao número de somas utilizadas para a extração do vetor de características que é apresentado à rede. Como o vetor de características é a média de cada uma das linhas de uma vizinhança quadrada de $k \times k$ pixels, o número de somas utilizadas na extração desse vetor é dado por k^2 , pois são k médias para cada uma das k linhas da vizinhança. Dessa forma, $NSGN$ é dado pela equação 4.14.

$$NSGN = n^2 \cdot ((k + 1) \cdot m + 2 \cdot (m + 1) + k^2) \quad (eq. 4.14)$$

A Tabela 4.2 exibe os valores do número de somas e multiplicações para os filtros testados na seção anterior, que são os filtros tradicionais de 13x13 e 17x17 pixels e o filtro neural proposto, que utiliza uma vizinhança de 13x13 e 3 neurônios na camada escondida. Os filtros foram utilizados em uma imagem de 800x800 pixels.

Comparando-se o filtro de Gabor Neural com o filtro da primeira linha da Tabela 4.2, pode-se observar que o método proposto executa aproximadamente 1,3 somas a mais, porém, executa 3,75 multiplicações a menos. Porém, comparando-se o filtro neural com os filtros complexos, tanto de 13x13 como de 17x17, o ganho se dá tanto no número de multiplicações como de somas. Isto ocorre devido ao fato de que no filtro de Gabor complexo a parte real e imaginária são obtidas através de duas

convoluções independentes, enquanto que no filtro neural, os dois neurônios de saída compartilham as informações geradas pela camada escondida, ou seja, existe uma correlação entre a parte real e imaginária que é aproveitada pela rede neural.

Filtro	Número de Multiplicações	Número de Somas
Gabor de 13x13	$1,0816 \times 10^8$	$1,0816 \times 10^8$
Gabor complexo de 13x13	$2,1632 \times 10^8$	$2,1632 \times 10^8$
Gabor de 17x17	$1,8496 \times 10^8$	$1,8496 \times 10^8$
Gabor Complexo de 17x17	$3,6992 \times 10^8$	$3,6992 \times 10^8$
Gabor Neural de 13x13	$2,88 \times 10^7$	$1,4016 \times 10^8$

Tabela 4.2 – Comparação do número de multiplicações e somas utilizadas pelo método proposto e o método tradicional. Observe que o número de somas do método proposto está na mesma ordem de grandeza dos demais métodos, porém, o número de multiplicações reduziu em uma ordem.

5 SEGMENTAÇÃO DA REGIÃO DE INTERESSE

Como mencionado no Capítulo 3, a detecção da região de interesse é de extrema importância para o processo de extração de minúcias. Neste capítulo este problema é apresentado de forma mais detalhada e é feita uma proposta de um método baseado em redes neurais, capaz de detectar as regiões da imagem que façam parte da impressão digital.

5.1 Segmentação

A segmentação da região de interesse tem por objetivo identificar as regiões da imagem onde existe a possibilidade de haver minúcias. Esta fase é importante para evitar que o codificador tenha que processar toda a imagem, e também para minimizar a quantidade de falsas minúcias que o codificador possa detectar processando áreas que não pertencem a uma impressão digital. O método de segmentação utilizado depende do contexto, por exemplo, em um ambiente controlado, em que a digital é colhida sobre uma folha de papel em branco, o método de segmentação pode ser mais simples. Já em casos como fichas utilizadas para identificação civil, como as do IFP, o método deve ser mais bem elaborado, pois geralmente nestas fichas encontram-se anotações feitas pelos peritos que as manipulam, como exibido na Figura 5.1.

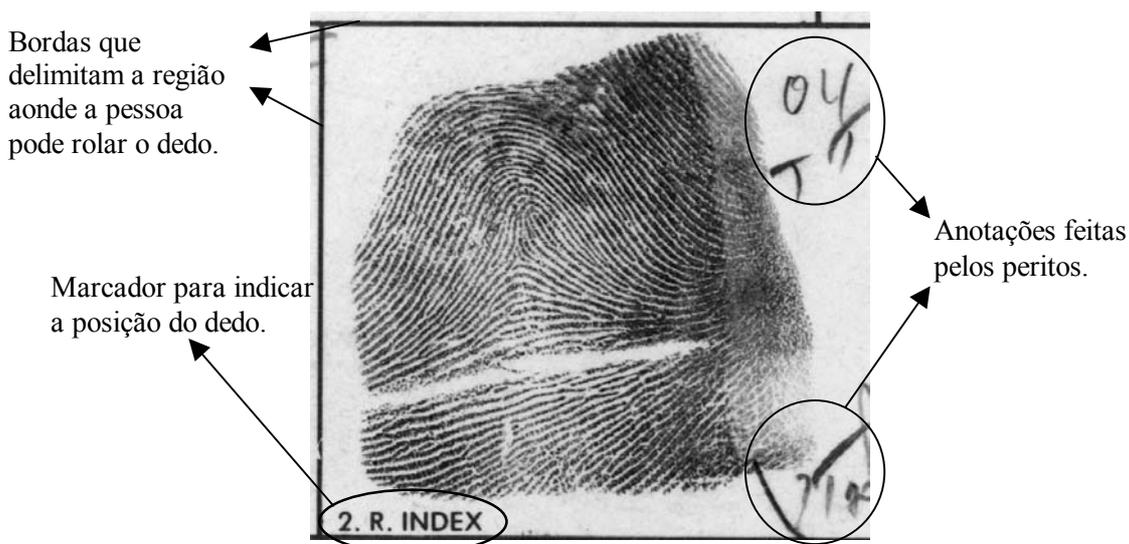


Figura 5.1 – Imagem de uma impressão digital colhida em uma ficha de identificação. Observe os vários elementos que também se encontram na imagem e não fazem parte da digital.

Em (JAIN, 1989) é apresentado um método de segmentação genérico, ou seja, o método não é específico para impressões digitais, e seu objetivo é localizar qualquer tipo de padrão dentro de uma imagem. Este método é pouco utilizado em impressões digitais, pois como ele é genérico seriam necessários que vários padrões de impressões fossem comparados contra a imagem.

Em (RATHA *et. al*, 1996) é proposto um método de segmentação de impressões digitais que utiliza a informação da variância dos tons de cinza da imagem, já que em regiões que possuem linhas de impressão digital apresentam uma variância alta. Este método funciona muito bem para separar as regiões de baixo contraste, como regiões de má qualidade da impressão digital ou o fundo, de regiões de alto contraste (regiões boas).

5.2 Proposta de um novo Método de Segmentação

No decorrer desta seção será apresentado um método baseado em redes neurais, capaz de localizar e separar as regiões que contém partes de impressão digital das demais áreas da imagem. Todas as imagens de impressões exibidas ou utilizadas neste trabalho estão em tons de cinza codificados com 8 bits e resolução de 500 ppp (pontos por polegada). As imagens foram obtidas do arquivo NIST (GARRIS, MCCABE, 2000).

O método proposto consiste basicamente em subdividir a imagem em blocos não superpostos de 32x32 pixels; extrair descritores de Fourier de cada bloco; utilizar uma rede neural para classificar cada bloco como sendo ou não parte de uma impressão digital; pós-processar a saída da rede e finalmente rotular cada pixel da imagem como pertencente ou não a região de interesse. As subseções seguintes descrevem cada uma das etapas e os resultados obtidos.

5.2.1 Subdivisão da Imagem e a Obtenção do Vetor de Características

Como dito no Capítulo 3, uma impressão digital é formada por linhas que possuem largura aproximadamente constante, e ao se analisar um fragmento pequeno da

impressão, observa-se que ele se assemelha a uma função senoidal bidimensional (JAIN, PANKANTI, 1997), como exibido na Figura 5.2.

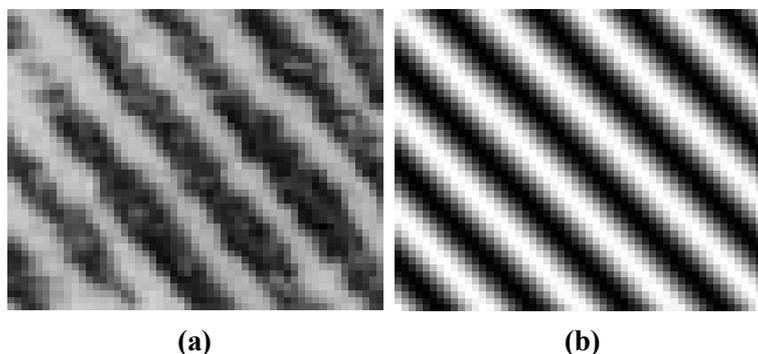


Figura 5.2 – (a) Imagem de um fragmento de impressão digital; (b) Imagem de uma senóide bidimensional com mesma direção de (a).

Ao se analisar o espectro da resposta em frequência de uma impressão digital percebe-se um acúmulo de energia em torno de um anel, que ocorre devido ao fato das linhas se comportarem como senóides, ou seja, possuem resposta em frequência bem definida. Uma vez que as linhas de uma impressão digital podem ocorrer em várias direções diferentes, e como a frequência no domínio da Transformada de Fourier bidimensional é calculada pela distância do ponto ao centro do gráfico, verifica-se que a imagem de uma impressão digital é formada por várias senóides com frequências bem definidas em diferentes direções. A Figura 5.3 exibe a imagem de uma impressão digital e seu espectro de Fourier.

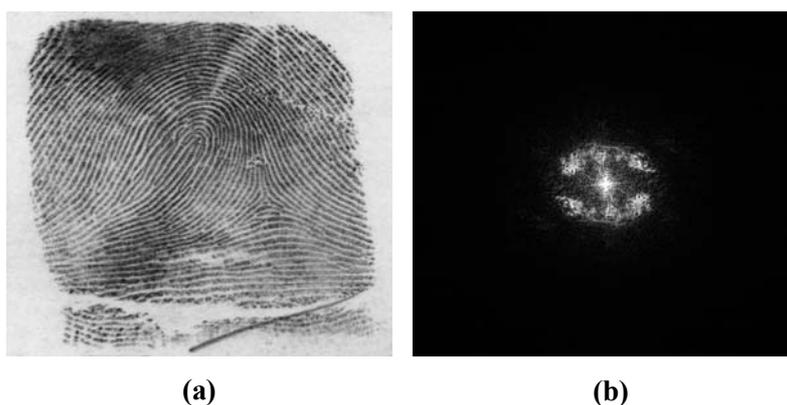


Figura 5.3 – (a) Imagem de uma impressão digital; (b) Espectro de Fourier de (a). Existe um anel onde se concentra energia.

Como visto na Figura 5.2, um fragmento pequeno de impressão digital se assemelha a uma senóide, e assim espera-se que seu espectro de Fourier seja parecido

com o espectro de uma senóide, que são dois impulsos simetricamente posicionados em relação à origem. A Figura 5.4 mostra os espectros de Fourier das figuras 5.2(a) e 5.2(b), sem a componente central, que consiste apenas na média de tons de cinza da imagem. Observe que, como esperado, a similaridade entre ambos é bastante elevada.

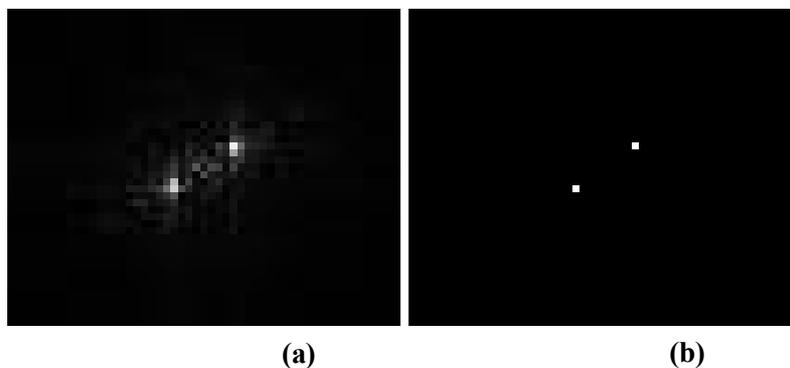


Figura 5.4 – (a) Espectro de Fourier da Figura 5.2(a); (b) Espectro de Fourier de Fourier da Figura 5.2(b). Observe como os espectros tendem a concentrar energia em dois pontos.

Pelo fato de um fragmento de impressão digital se assemelhar a uma onda senoidal o modelo de segmentação proposto neste trabalho consiste em dividir a imagem em vários blocos de 32x32 pixels e extrair, para cada bloco, um vetor de características baseado em sua transformada de Fourier. Cada um desses vetores é posteriormente passado a uma rede neural que se encarrega de classificar cada bloco como sendo ou não um fragmento de impressão digital.

O vetor de características poderia ser o próprio espectro de Fourier, mas existem dois problemas nesta abordagem: primeiro, a transformada de Fourier não é invariante à rotação, isto é, apresenta resultados distintos para fragmentos de impressões digitais cujos fluxos das linhas estejam orientados em direções diferentes; segundo, o tamanho do vetor de características é muito grande, pois a transformada de Fourier de uma matriz de dimensão 32x32 é também uma matriz de 32x32, ou seja, possui 1024 elementos. Se for considerada a simetria do espectro poderia utilizar-se apenas 512 elementos, o que seria ainda um vetor muito grande para se apresentar a uma rede neural.

Cada elemento do espectro de Fourier contém um valor proporcional à amplitude de uma senóide cuja frequência é proporcional à distância deste elemento ao centro do espectro. Por exemplo, seja $F(u, v)$ a transformada de Fourier de uma função $f(x, y)$, onde u e v representam as frequências horizontal e vertical respectivamente. Se o

elemento $F(u_0, v_0)$ for igual a A_θ , sabe-se que a senóide de frequência $\sqrt{u_0^2 + v_0^2}$ e direção θ , dada por $\theta = \arctan(v_0/u_0)$, possui amplitude, ou energia, proporcional a A_θ .

Portanto se o objetivo é extrair características invariantes à rotação, é preciso basear-se apenas na informação de amplitude e de frequência, ou seja, na distância de cada elemento do espectro de Fourier ao centro da transformada. Tal procedimento equivale a somar a energia de todas as senóides de mesma frequência e armazenar este valor para cada frequência possível.

Para que o tamanho do vetor de características seja constante calcula-se o valor da maior e da menor frequências possíveis e faz-se uma quantização do intervalo em uma quantidade finita de níveis. Neste trabalho optou-se por utilizar 21 níveis, criando um vetor cujos índices variam de 0 a 20. A seguir percorre-se o espectro da transformada de Fourier calculando, para cada elemento (u, v) , a sua frequência e a sua posição dentro do vetor de características, e acumula-se o valor de sua energia na posição correspondente. A maior frequência possível é dada pela distância de um elemento da diagonal ao centro, e a menor é zero.

Deve-se observar, no entanto, que quando a posição do vetor de características for calculada o seu valor não é inteiro, portanto, deve-se utilizar algum método para indexar o vetor. A maneira mais simples é arredondar o valor para o inteiro mais próximo. No entanto, neste trabalho foi escolhido dividir a energia de forma ponderada entre as duas posições inteiras mais próximas, por exemplo, se o valor calculado for 3.7, na posição três do vetor é acumulado 30% da energia e na posição quatro 70%. Depois de calculado o vetor de características, este é normalizado dividindo-se as 21 posições pela sua soma total, fazendo com que a rede receba vetores de características cujos valores sempre variem dentro de uma faixa contínua entre 0 e 1, independente da imagem de origem.

Para que os tons de cinza de cada bloco variem dentro de um intervalo regular, cada bloco é equalizado, utilizando-se o algoritmo descrito em (GONZALEZ, WOODS, 2000) antes de se extrair o vetor de características.

Ao vetor de características é ainda acrescentada uma informação referente à consistência de direção das linhas da impressão digital. Esta informação é calculada computando-se a direção predominante dos gradientes da imagem (JAIN, PANKANTI,

1997). Sendo m_1 a soma das projeções dos gradientes sobre a direção predominante e m_2 a soma das projeções na direção perpendicular, a consistência de direção é obtida pela equação 5.1.

$$\frac{m_1 - m_2}{m_1 + m_2} \quad (\text{eq. 5.1})$$

O valor resultante desta equação estará sempre dentro do intervalo 0 e 1. Se o fragmento for de uma impressão digital a consistência de direção assumirá um valor alto.

Acrescentando-se a informação de consistência de direção ao vetor de características este passa a ter 22 posições. A Figura 5.5 exibe um fragmento de impressão digital, seu respectivo espectro e o vetor de características extraído conforme explicado nos parágrafos anteriores desta sessão. Observe que a maior concentração de energia ocorre na 3ª posição do vetor, e que a consistência de direção assume um valor elevado.

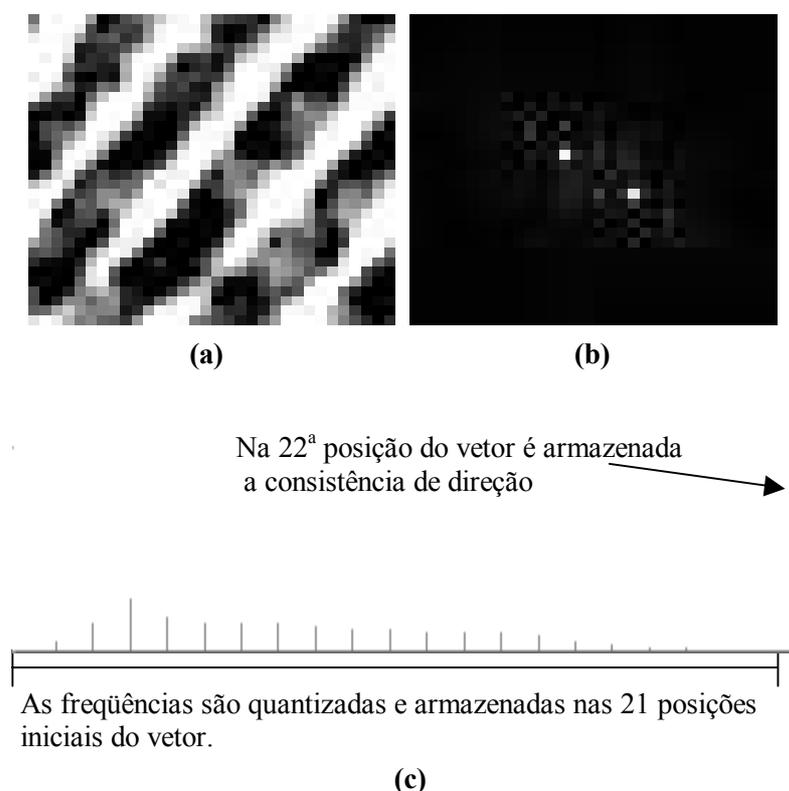


Figura 5.5 – (a) Imagem de um fragmento de impressão digital; (b) Espectro de Fourier de (a) sem o componente central; (c) Vetor de características obtido do espectro de Fourier da imagem (c). Observe que a maior concentração de energia ocorre na 3ª posição do vetor e a consistência de direção é alta.

A Figura 5.6 exibe o fragmento de uma imagem que não é uma impressão digital, seu respectivo espectro de Fourier e seu vetor de características. Note que a energia ficou distribuída mais uniformemente entre as posições do vetor e a consistência de direção é bem mais baixa que na Figura 5.5.

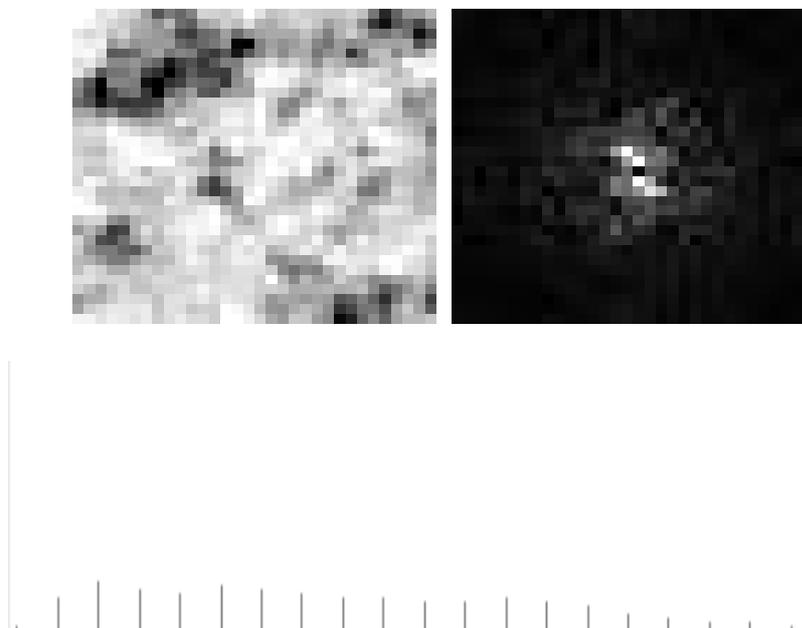


Figura 5.6 – Imagem de um fragmento que não é uma impressão digital, seu espectro de Fourier sem o componente central e seu vetor de características obtido do espectro de Fourier da imagem. Observe que a energia está menos concentrada do que na Figura 5.5, e que a consistência de direção está baixa.

5.2.2 A classificação Neural

A rede neural escolhida para a classificação de cada bloco da imagem foi do tipo MLP com arquitetura 22x13x2. A rede recebe como entrada o vetor de características de 22 posições e gera como saída o vetor (1, 0) quando a entrada corresponder a um fragmento de impressão digital e (0, 1) caso contrário.

O algoritmo de treinamento utilizado foi o *backpropagation* (RUMELHART,, HINTON, WILLIAMS, 1986; HAYKIN, 2001) com taxa de aprendizado 0.3, momento 0.9 e erro máximo 0.01. A base de treinamento contém 3690 padrões, sendo 1812 correspondentes a blocos que são impressões digitais e 1878 que não são impressões digitais. A rede convergiu para um erro de 0.0157371 em 350 ciclos de treinamento, não

atingindo o erro desejado. A plataforma de treinamento utilizada foi o MatLab versão 6.1 da MathWorks Inc.

5.2.3 Implementação da Segmentação

Com a rede neural treinada, a segmentação poderia ser feita da seguinte forma: percorre-se a imagem pixel a pixel, obtendo-se uma janela de 32x32 centralizada no pixel corrente, extrai-se o vetor de características da janela, submete-se o vetor à rede e, se a resposta da rede indicar que é uma impressão digital, rotula-se este pixel com 1 senão rotula-se com 0. Após toda a imagem ser percorrida tem-se um rótulo para cada pixel sabendo exatamente se pertence ou não a área de interesse.

O problema desse método é o custo computacional muito alto. Uma alternativa é utilizar um algoritmo de janela deslizante com passo arbitrário. Se o passo for 1, o algoritmo será equivalente ao descrito inicialmente. Se o passo for maior que 1, nem todos os pixels serão computados, mas somente aqueles que forem centro de alguma janela. Nesta estratégia faz-se necessário utilizar um método de interpolação que estime uma possível resposta da rede para os pixels que não foram centro de nenhuma janela. Neste trabalho foi escolhido utilizar um método de janela deslizante com passo de tamanho 32, o que equivale a dividir a imagem em janelas de 32x32 pixels não superpostas, e utilizar o método de interpolação bilinear para rotular os pixels não computados diretamente pela rede.

O método de interpolação bilinear consiste em calcular, para cada pixel desejado, a média ponderada pela distância aos 4 pixels vizinhos mais próximos que sejam centro de suas respectivas janelas. Como a saída da rede é um vetor de duas posições, é necessário o uso de uma matriz N_1 para armazenar a saída do 1º neurônio e uma matriz N_2 para armazenar a saída do 2º neurônio, e a interpolação é calculada em ambas as matrizes. A Figura 5.7 exhibe este procedimento. Como consequência da interpolação obtém-se uma estimativa da resposta da rede para cada pixel da imagem, e a seguir, seguindo o mesmo critério adotado para os pixels centrais das janelas, rotula-se cada pixel baseado na saída estimada da rede.

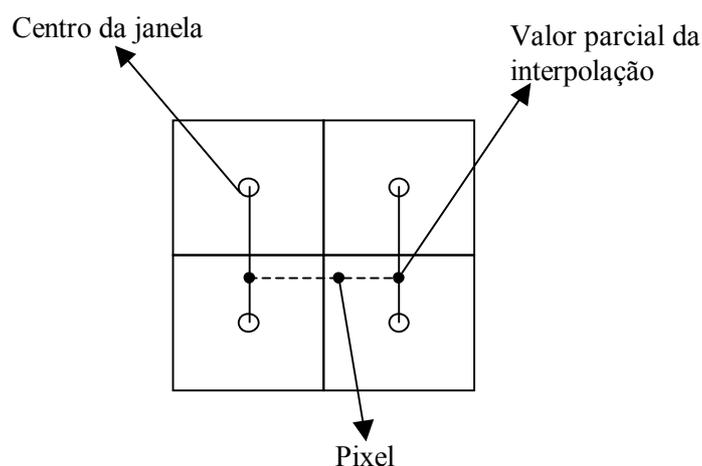


Figura 5.7 – Método de interpolação bilinear que é aplicado nas matrizes N_1 e N_2 para se preencher os pixels que não são centros de nenhuma janela.

O critério adotado para interpretação da resposta da rede foi o seguinte: cada pixel é rotulado como sendo uma impressão digital se a saída do neurônio 1 for maior ou igual a 0.5 e a saída do neurônio 2 menor que 0.5, e rotulado como não sendo uma impressão digital caso contrário. Com o processo de rotulação monta-se uma matriz L que contém 1's nas posições correspondentes a pixels pertencentes a uma impressão digital e 0's nas demais.

Depois de obtida a matriz L ela é submetida a um algoritmo de rotulação de regiões (JAIN, 1989) que gera como saída uma lista de regiões conexas devidamente rotuladas. Para cada região são computados dois valores, a sua área (total de pixels em seu interior), e o seu raio mínimo, R_{min} , que é obtido da seguinte forma: primeiro computa-se o centro de massa da região e a sua direção predominante (JAIN, 1989); depois computa-se para cada pixel o valor absoluto da projeção do vetor que o liga ao centro de massa sobre a direção perpendicular a direção predominante. R_{min} é o valor absoluto da menor projeção.

Todas as regiões que possuem área menor do que uma certa quantidade de pixels (2500 no caso deste trabalho) ou R_{min} menor que um certo valor (20 neste caso) são retiradas da lista. As regiões restantes são consideradas partes da impressão digital.

5.3 Experimentos e Resultados

O método descrito na seção anterior foi implementado em C++, porém a rede neural foi treinada no MatLab, como mencionado na Seção 5.2.2. Foram feitos testes em algumas imagens e as figuras de 5.8 a 5.14 exibem alguns dos resultados obtidos.



Figura 5.8 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.



Figura 5.9 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.



Figura 5.10 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.

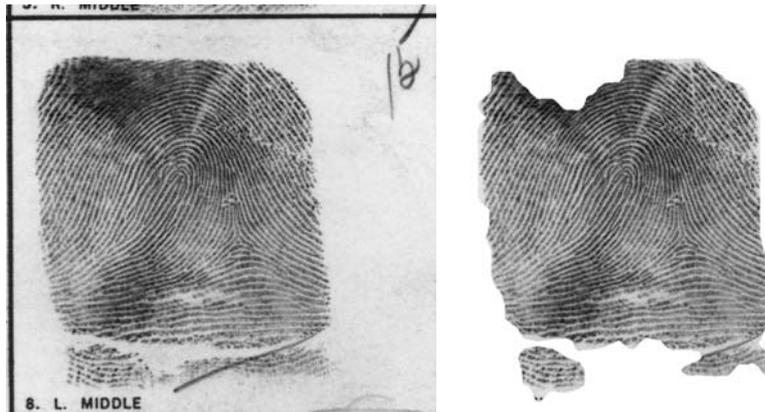


Figura 5.11 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.

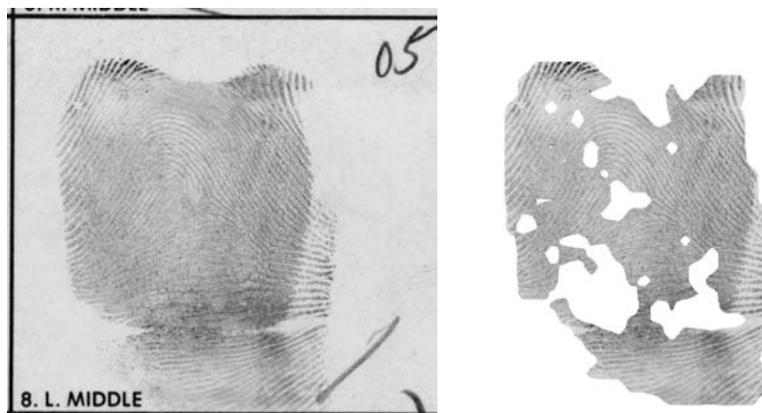


Figura 5.12 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.



Figura 5.13 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.

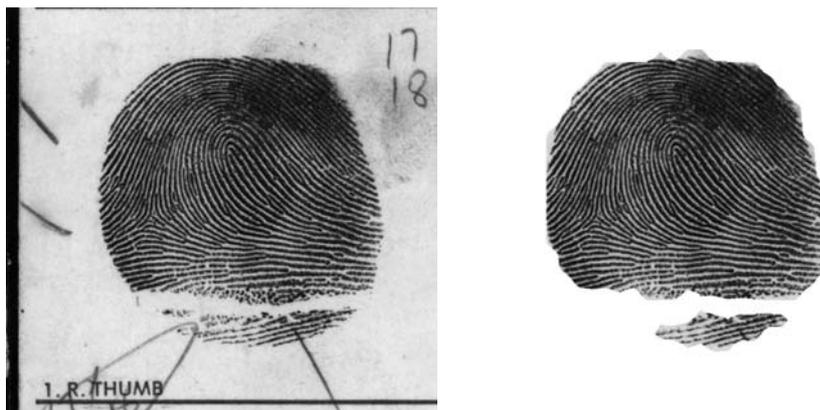


Figura 5.14 – Esquerda: Imagem de uma impressão digital. Direita: Imagem segmentada utilizando o método proposto.

5.4 Métrica para Avaliação de Desempenho

Para medir de forma precisa a qualidade do resultado alcançado, a segmentação feita automaticamente é comparada com uma segmentação feita manualmente. Sendo R_1 a região obtida pelo método proposto e R_2 a região gabarito definida manualmente, duas medidas são calculadas, o ca (Coeficiente de Acerto) e o ce (Coeficiente de Erro) que são dados respectivamente, pelas equações 5.2 e 5.3.

$$ca = \frac{\text{Área}(R_1 \cap R_2)}{\text{Área}(R_2)} \quad (\text{eq. 5.2})$$

$$ce = \frac{\text{Área}(R_1 - R_2)}{\text{Área}(R_2)} \quad (\text{eq. 5.3})$$

Das equações acima pode-se observar o seguinte:

- o coeficiente de acerto (ca) indica o quanto da região que faz parte da impressão digital foi corretamente detectada pelo segmentador. Se ca for 1, indica que toda a região que faz parte da impressão digital foi corretamente detectada pelo segmentador, enquanto que zero indica que nenhuma região da impressão digital foi detectada;
- o coeficiente de erro (ce) indica o quanto da imagem foi erroneamente detectado pelo segmentador como sendo parte da impressão digital. Se ce for zero, indica que o segmentador não detectou incorretamente nenhuma região. Se ce for 1, indica que o tamanho da área incorretamente detectada como sendo

parte da impressão digital é do mesmo tamanho da área que faz parte da impressão digital. Observe que ca está limitado entre 0 e 1, enquanto que ce tem limite inferior zero, porém não tem limite superior.

O que se deseja, portanto, é que o segmentador tenha o valor mais alto possível para ca e o mais baixo possível para ce . Portanto, neste trabalho, é utilizado a diferença entre ca e ce para se medir a qualidade da segmentação, esta diferença é chamada de cq (Coeficiente de qualidade) e é dada pela equação 5.4. Idealmente, é desejável que cq seja 1.

$$cq = ca - ce \quad (eq. 5.4)$$

A Tabela 5.1 exibe os valores de ca , ce e cq para as imagens das figuras 5.8 a 5.14.

Figura	ca	ce	cq
5.8	0.8865	0.0399	0.8466
5.9	0.9368	0.1015	0.8353
5.10	0.9174	0.0485	0.8688
5.11	0.9057	0.0210	0.8848
5.12	0.7427	0.0209	0.7218
5.13	0.9340	0.0691	0.8649
5.14	0.9522	0.0150	0.9372

Tabela 5.1 – Coeficientes de acerto, erro e de qualidade para cada uma das imagens das figuras 5.8 a 5.14, obtidos através do segmentador proposto.

Pode-se observar da Tabela 5.1 que com exceção da Figura 5.12, o segmentador obteve um coeficiente de qualidade maior que 0.84. Deve-se observar, no entanto, que a imagem da Figura 5.12 é uma imagem de baixa qualidade, por isso, o seu índice de qualidade não foi tão alto.

5.5 Pós-Processamento com Filtragem Morfológica

Observando as imagens segmentadas pode-se notar que elas apresentam uma série de falhas ou buracos internos deixados pelo segmentador. Observa-se, no entanto, que uma região que não tenha sido classificada como sendo parte da impressão digital, provavelmente foi mal classificada se ela estiver envolvida por regiões que fazem parte da impressão digital, como é o caso de alguns dos buracos presentes nas imagens testadas. Ou seja, muito provavelmente, estes buracos também fazem parte da impressão digital.

Com o objetivo de reduzir estas más classificações foi testado o uso de uma operação morfológica de *Fechamento* seguida de uma operação de *Abertura* (JAIN, 1989) sobre a matriz L (Seção 5.2.3) antes do processo de rotulação. O uso destas duas operações para minimizar os erros de segmentação de impressões digitais foi proposto por (CHEN, TIAN, CHENG, YANG, 2004).

A Tabela 5.2 exibe os coeficientes ca , ce e cq para as mesmas imagens das Figuras 5.8 a 5.14, utilizando as operações de *Fechamento* e *Abertura*.

Figura	ca	ce	cq
5.8	0.8967	0.0556	0.8411
5.9	0.9541	0.1170	0.8371
5.10	0.9304	0.0535	0.8769
5.11	0.9172	0.0283	0.8890
5.12	0.7758	0.0229	0.7528
5.13	0.9539	0.0793	0.8747
5.14	0.9580	0.0190	0.9391

Tabela 5.2 – Coeficientes de acerto, erro e qualidade para cada uma das imagens das figuras 5.8 a 5.14, obtidos através do segmentador proposto, utilizando as operações de *fechamento* e *abertura*.

As figuras de 5.15 a 5.21 exibem a segmentação utilizando as operações morfológicas.

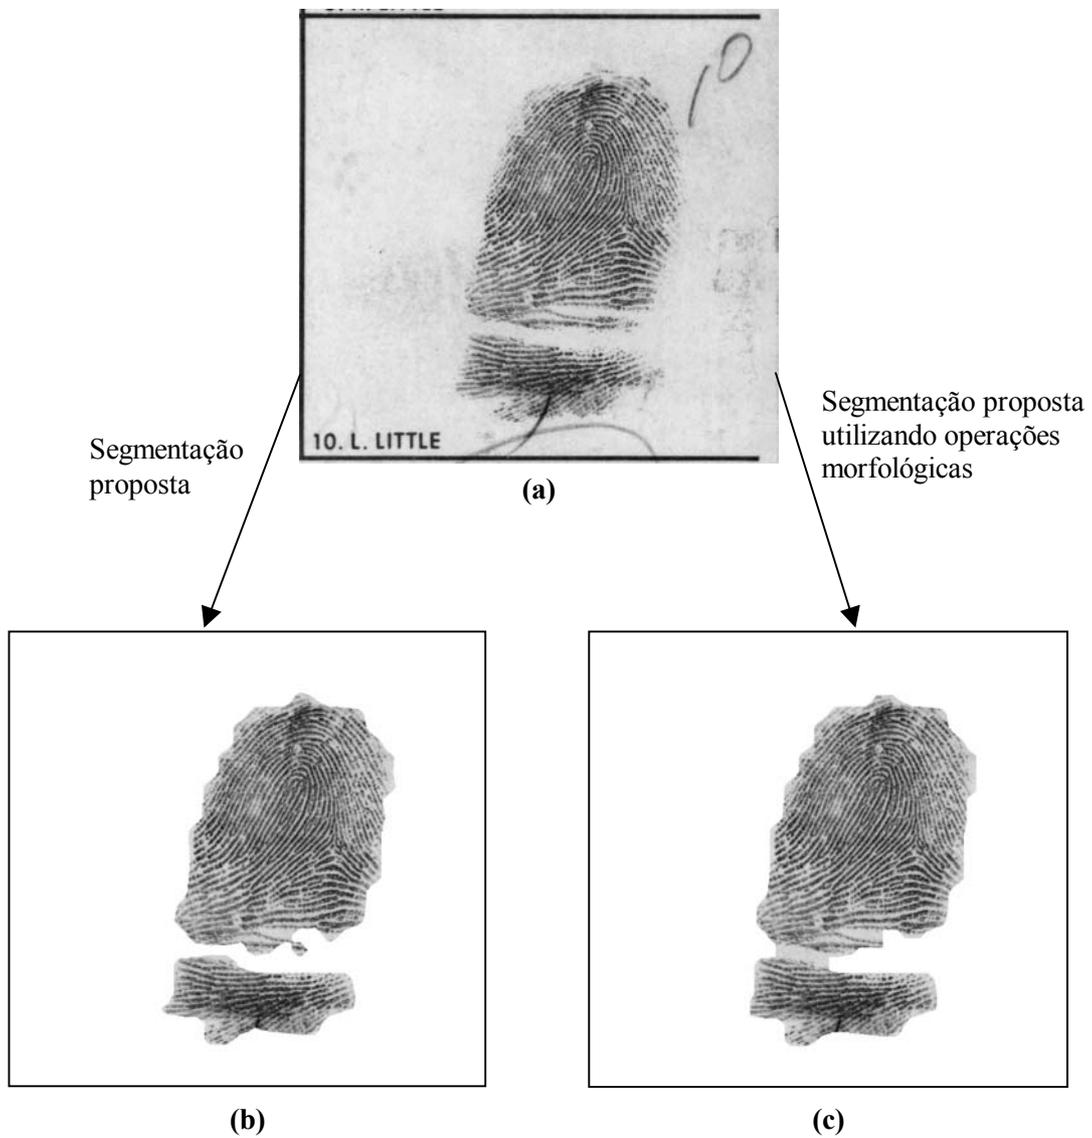


Figura 5.15 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.

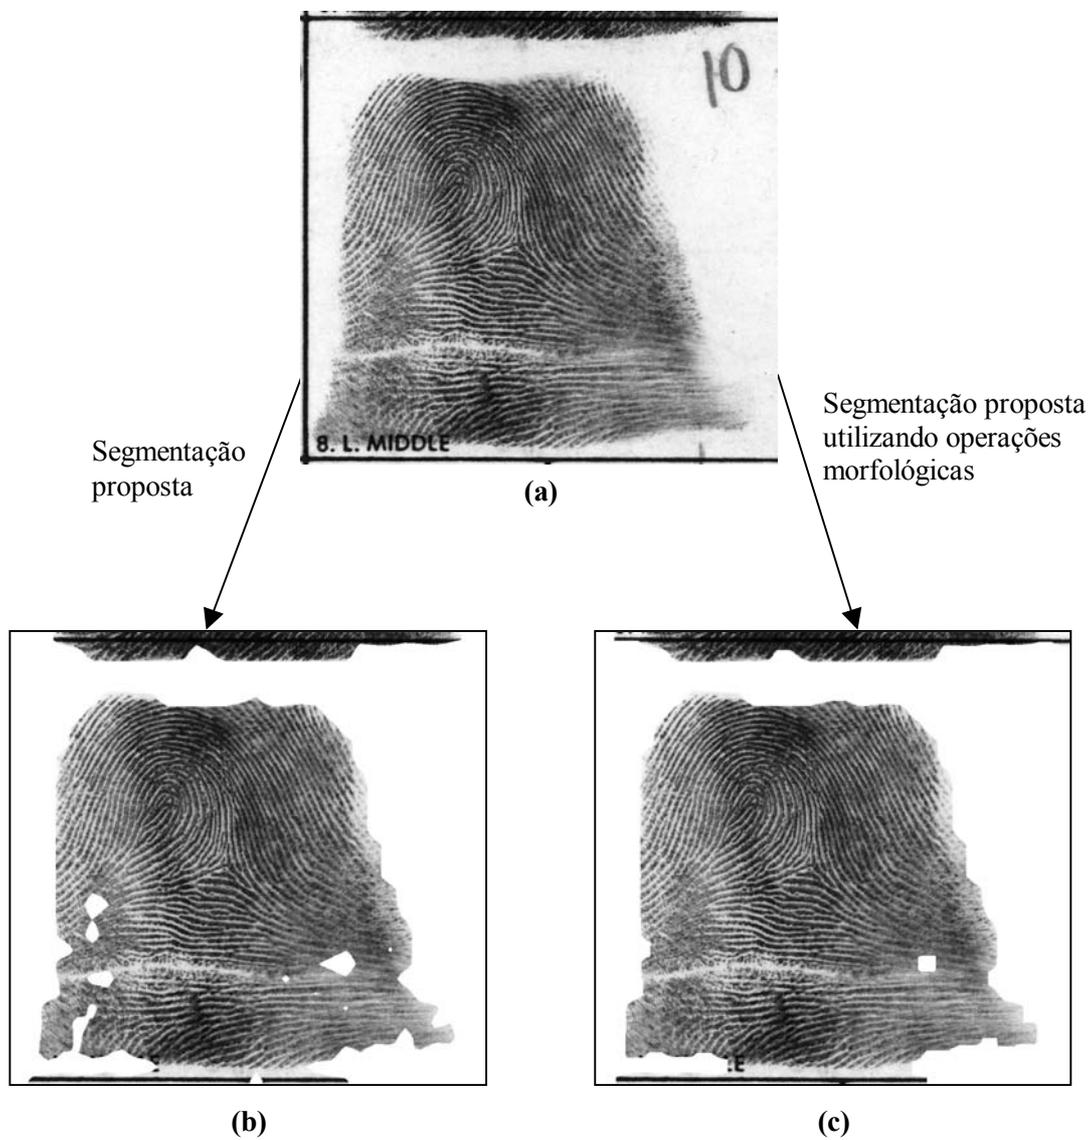


Figura 5.16 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.

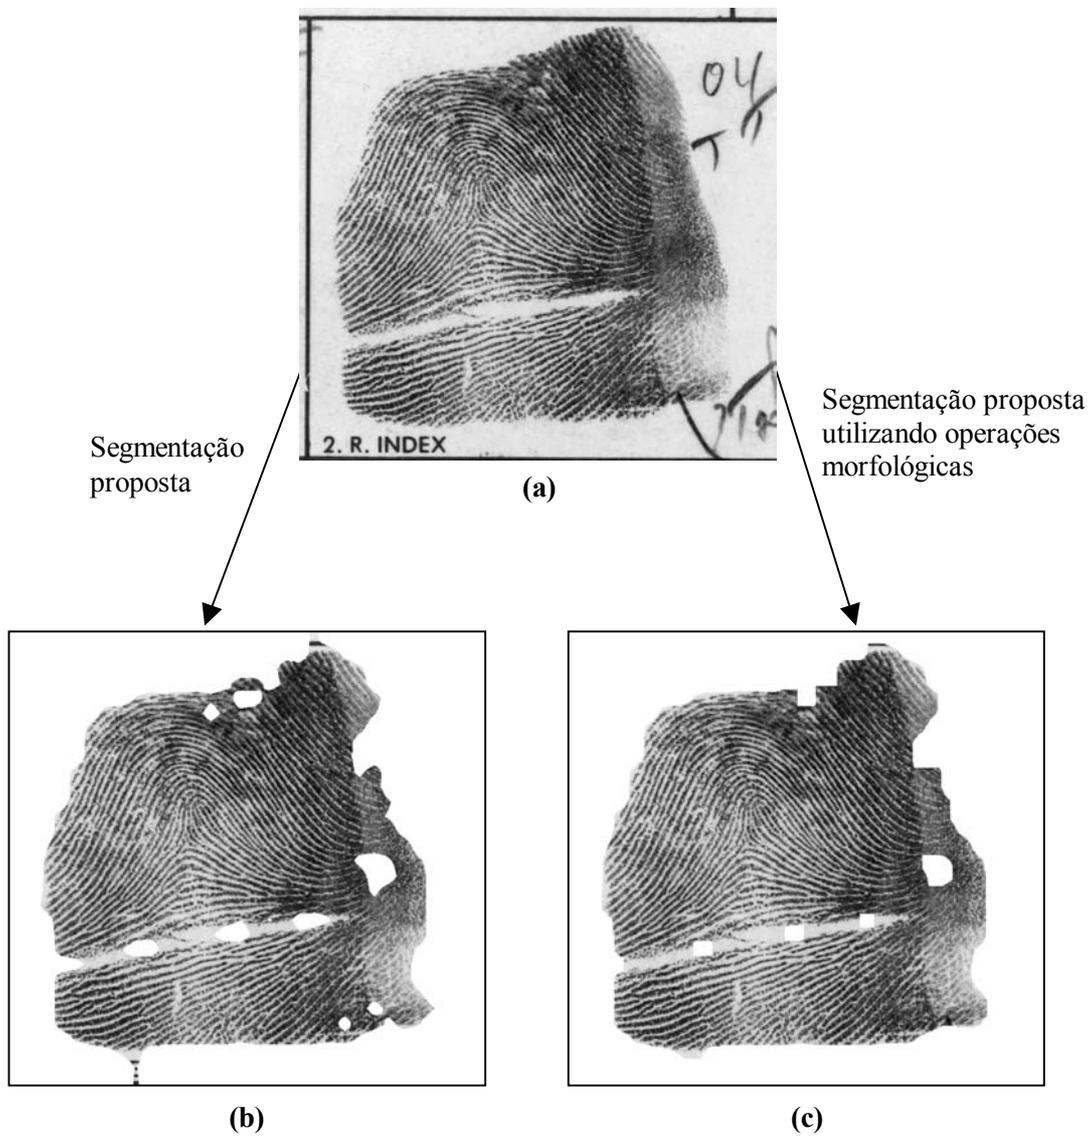


Figura 5.17 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.

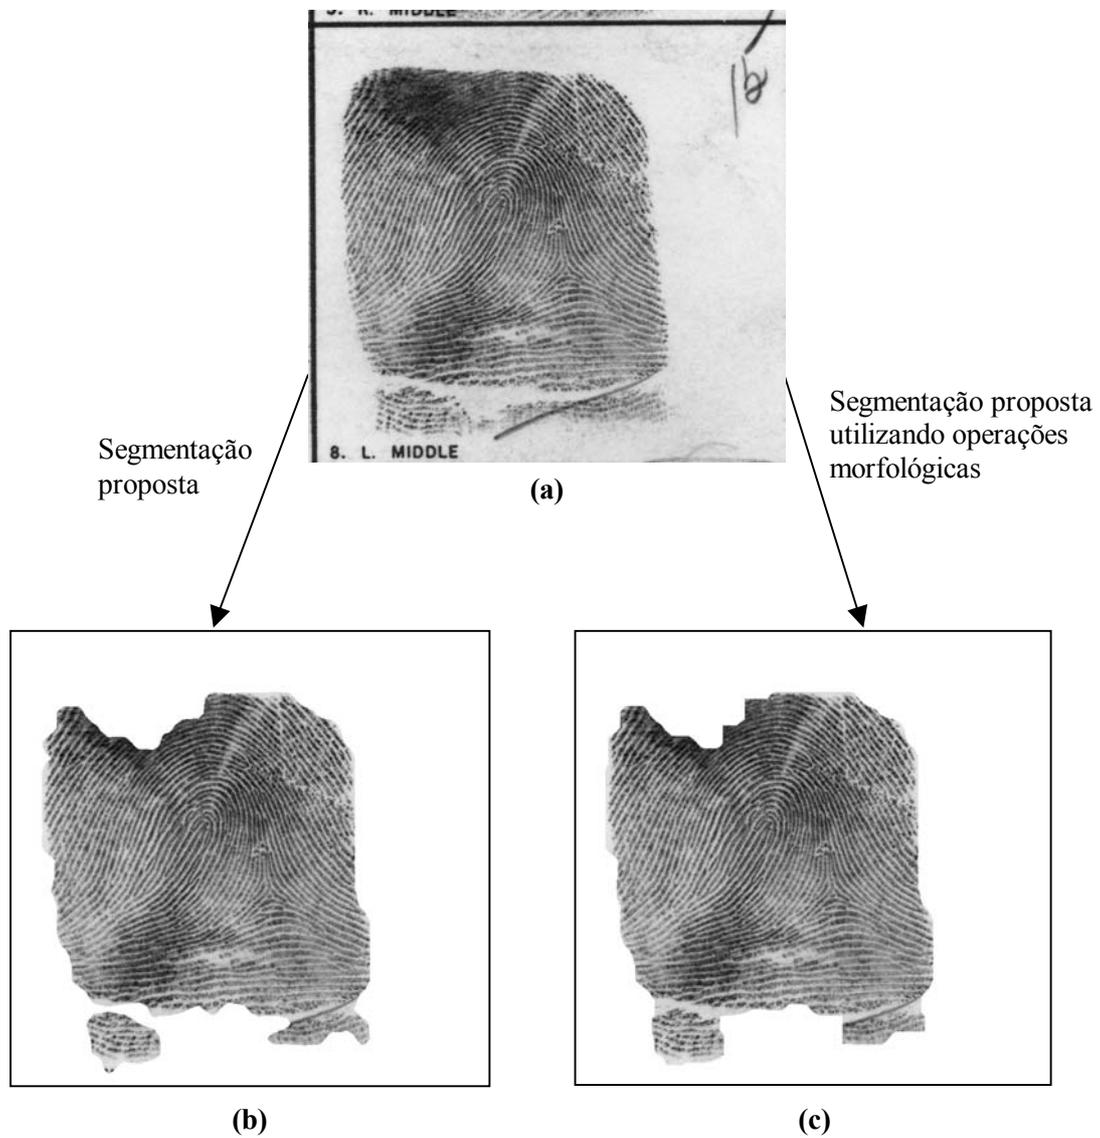


Figura 5.18 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.

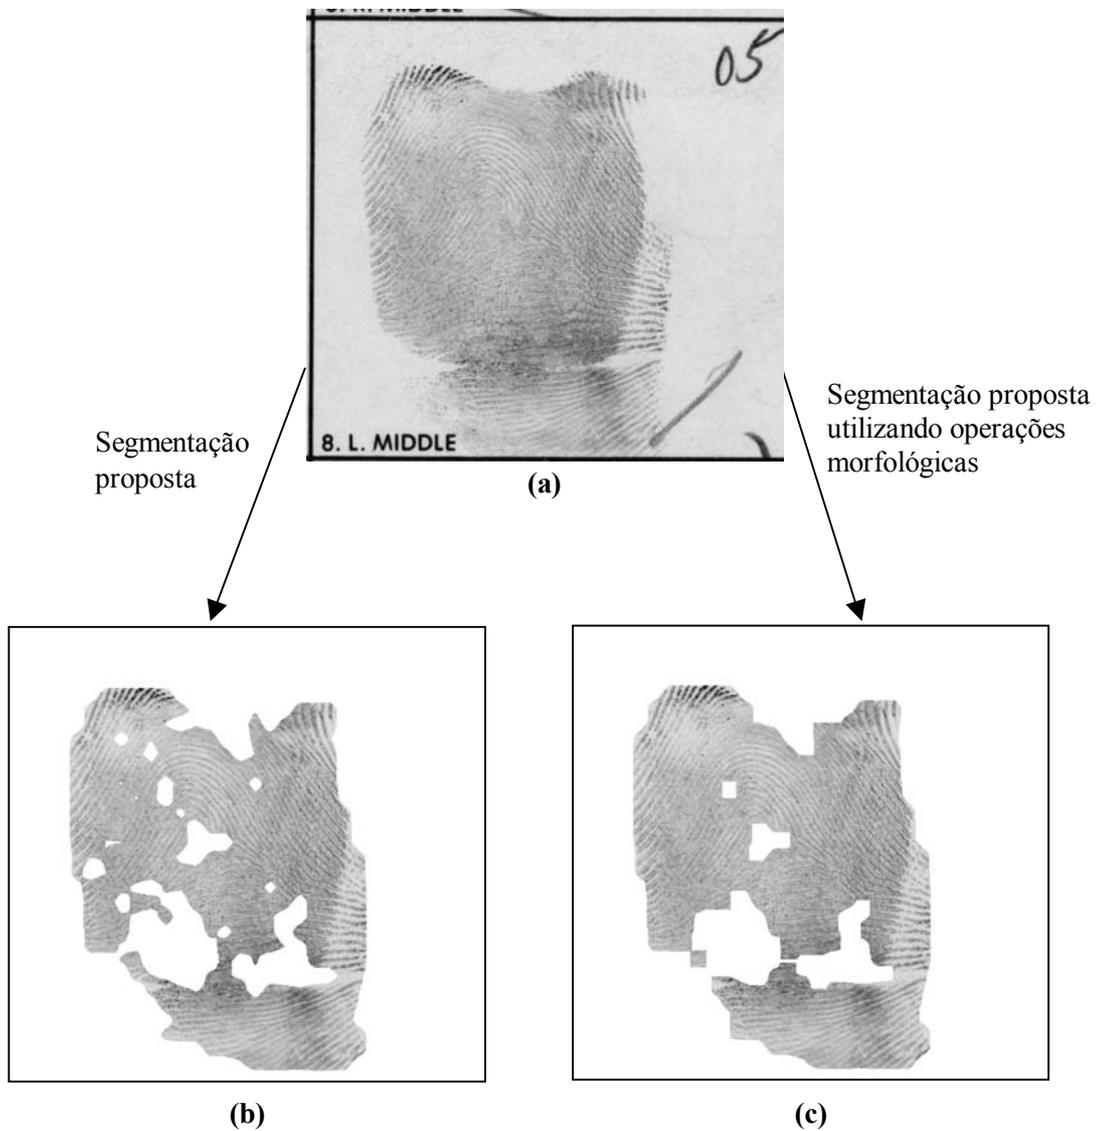


Figura 5.19 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.

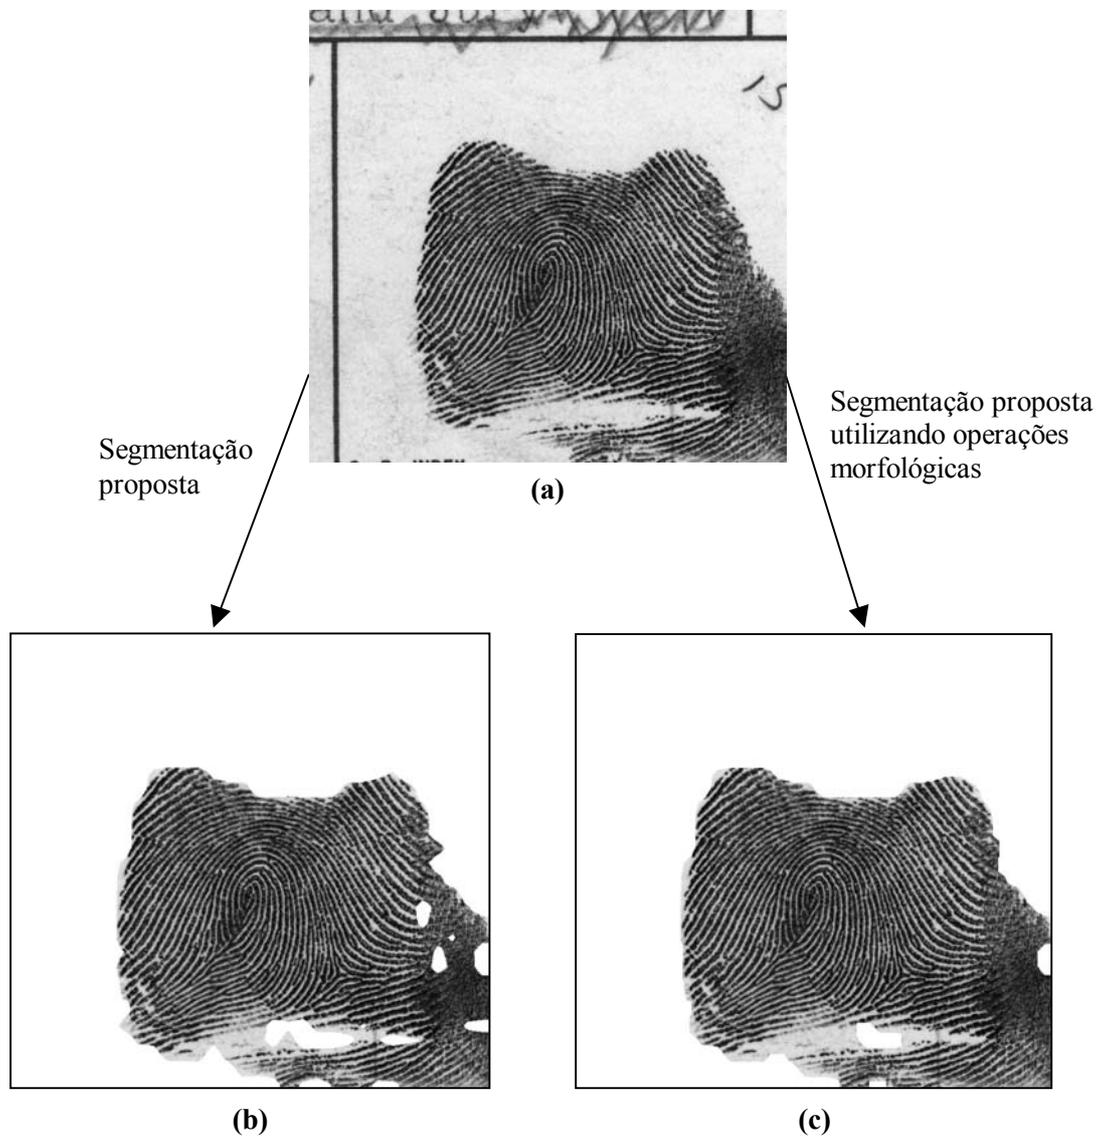


Figura 5.20 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.

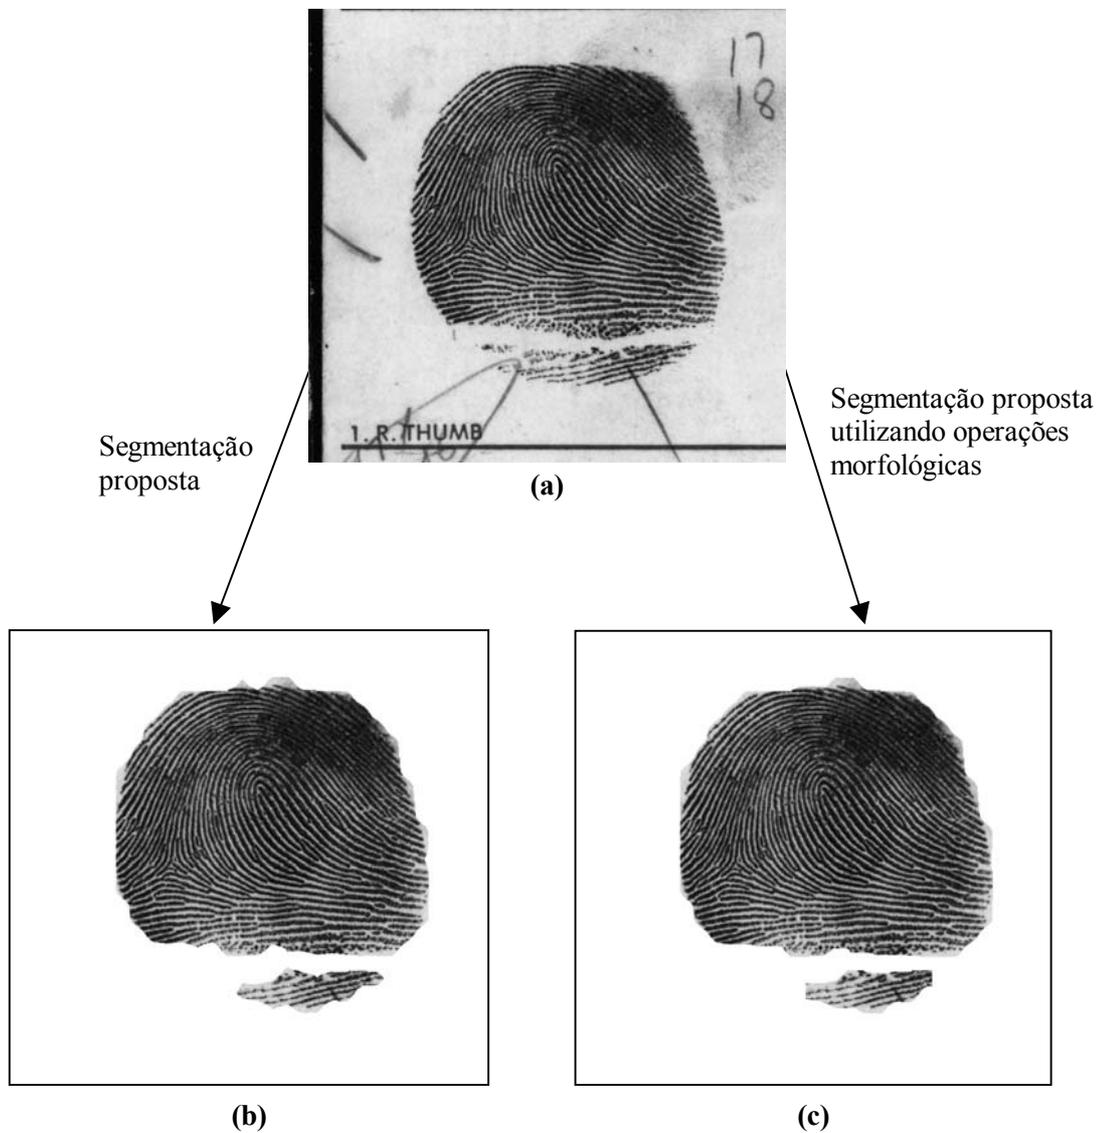


Figura 5.21 – (a) Imagem original; (b) Imagem segmentada utilizando o método proposto; (c) Imagem segmentada utilizando o método proposto, utilizando filtragem morfológica.

Comparando-se a Tabela 5.1 com a 5.2, pode-se notar que para a imagem da Figura 5.8 o valor de cq reduziu de 0.8466 (Tabela 5.1) para 0.8411 (Tabela 5.2), ou seja, a utilização das operações morfológicas nesta imagem provocou uma queda no coeficiente de qualidade da segmentação. Porém, o cq médio da Tabela 5.1 vale 0.8513, enquanto que o cq médio da Tabela 5.2 vale 0.8587, portanto, o uso das operações morfológicas provocou, em média, um aumento no cq , justificando assim seu uso.

5.6 Conclusão

Neste capítulo foi investigado o problema da detecção da região de interesse de uma imagem contendo uma impressão digital. As imagens das impressões digitais utilizadas para validar o modelo proposto estão armazenadas em meio eletrônico e foram capturadas em tons de cinza com 8 bits de profundidade e 500 ppp de resolução.

Para solucionar o problema foi proposto um método de segmentar a imagem ou localizar a área que contenha a impressão digital, que subdivide a imagem em pequenos blocos de 32x32 pixels, e para cada bloco é extraído um vetor de características baseado em seu espectro de Fourier. Este vetor possui 22 posições, sendo que as 21 primeiras posições contém informação sobre as respostas em frequências das senóides e a última posição possui uma informação relativa à consistência de direção das linhas da impressão digital contida no bloco.

A implementação foi feita em C++, e a rede neural foi treinada no MatLab da MathWorks Inc., versão 6.1. Os testes foram realizados com imagens obtidas do arquivo NIST (GARRIS, MCCABE, 2000). A medida cq (Coeficiente de Qualidade), representa a diferença entre a área relativa corretamente identificada (ca) e a área erroneamente identificada (ce). Nos testes o coeficiente cq obteve-se um valor médio de 0.8513.

A utilização das operações morfológicas aumentou o cq médio para 0.8587, portanto, pode-se concluir que compensa utilizar as operações morfológicas.

6 EXTRAÇÃO AUTOMÁTICA DE MINÚCIAS

Neste capítulo é feita a proposta de um extrator automático de minúcias baseado em redes neurais. Basicamente, o método consiste em utilizar um filtro para localizar regiões na imagem que possam conter minúcias. Depois, é utilizado um método de pós-processamento para validar as minúcias encontradas pelo filtro.

O filtro utilizado para localizar as regiões candidatas é o filtro de Gabor, que foi implementado através de uma rede neural, conforme proposta na Seção 4.4 desta dissertação.

O pós-processamento feito para validar as minúcias encontradas pelo filtro de Gabor consiste em um modelo neural que analisa cada região candidata a conter uma minúcia e a classifica como fim-de-linha, bifurcação ou não-minúcia.

Deste modo, o modelo do extrator de minúcias é composto por dois módulos, a saber, o filtro de Gabor complexo implementado através de uma rede neural (Seção 4.4), que será chamado de GNC (Gabor Neural Complexo) e um modelo neural utilizado para validar as minúcias extraídas que será chamado de MVN (Módulo de Validação Neural).

O processo consiste em filtrar a imagem com o filtro de Gabor e extrair regiões candidatas a serem minúcias, cada uma dessas regiões é então processada e classificada pelo MVN como sendo fim-de-linha, bifurcação ou não-minúcia. A Figura 6.1 exibe o funcionamento básico do extrator de minúcias.

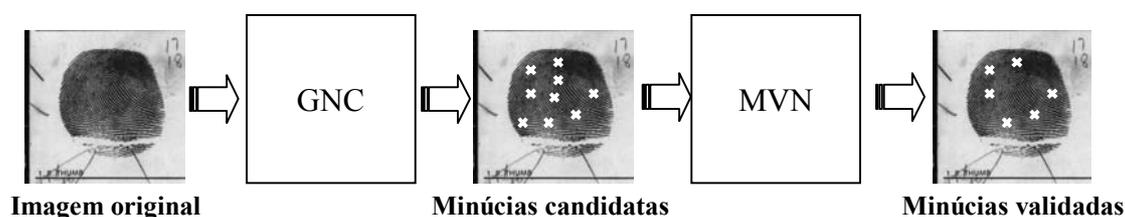


Figura 6.1 – Ilustração básica do funcionamento do extrator de minúcias.

Este capítulo está organizado da seguinte forma. As seções 6.1 e 6.2 exibem, respectivamente, os módulos GNC e MVN. A Seção 6.3 exibe os testes e avalia os resultados obtidos para cada módulo (GNC e MVN) em separado, e o desempenho final do extrator. A Seção 6.4 conclui o capítulo fazendo uma análise dos resultados obtidos.

6.1 Módulo GNC (Gabor Neural Complexo)

Como visto na Seção 4.3, a resposta do filtro de Gabor complexo gera um sinal complexo de saída. Ao gerar-se uma imagem onde cada pixel armazena o valor absoluto da resposta do filtro, observa-se que em regiões onde se encontram possíveis minúcias o módulo da resposta do filtro tende a ser baixo. A Figura 6.2 apresenta a imagem de uma impressão digital e a correspondente resposta do filtro de Gabor em tons de cinza.

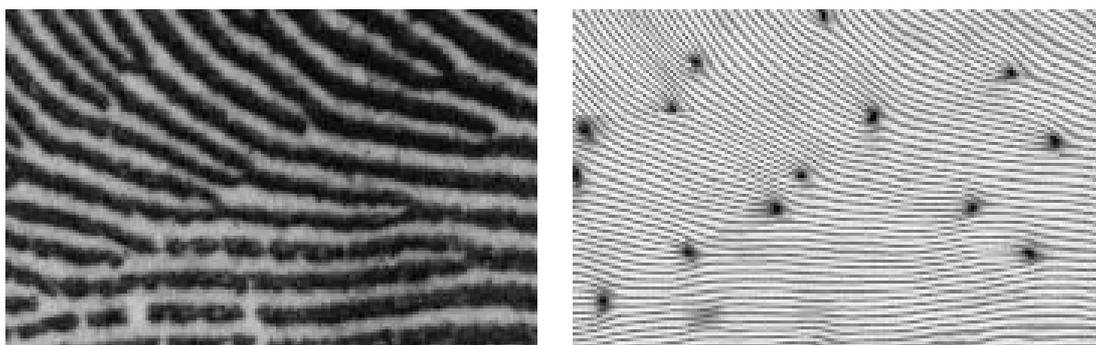


Figura 6.2 – A imagem da esquerda é um fragmento de impressão digital, e a imagem da direita é a imagem filtrada com o método proposto na Seção 4.4. Observe que as regiões próximas de minúcias ficam mais escuras.

Como o filtro se comporta desta forma, o processo de localização de minúcias consiste, basicamente, passar a imagem pelo filtro de Gabor, binarizar a resposta do filtro através de um limiar de corte L , e rotular os pixels pretos como sendo candidatos a minúcias. A Figura 6.3 exibe a imagem filtrada pelo Gabor da Figura 6.2 e a mesma imagem binarizada com um limiar $L = 100$.

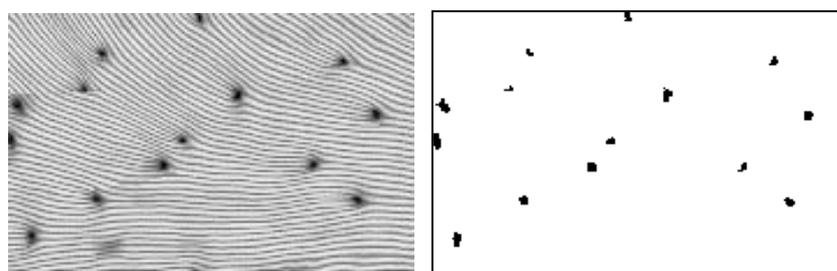


Figura 6.3 – A imagem à esquerda é o resultado da aplicação do filtro de Gabor na imagem da Figura 6.2, e a imagem à direita é o resultado de sua binarização com um limiar de corte $L=100$.

Após a binarização é aplicado um algoritmo de rotulação para extrair regiões conexas de imagens binárias (JAIN, 1989), e o pixel central de cada uma dessas regiões é considerado como sendo a posição de uma possível minúcia. A Figura 6.4 exibe a imagem da Figura 6.3 após a rotulação, exibindo os pixels centrais de cada uma das regiões conexas.

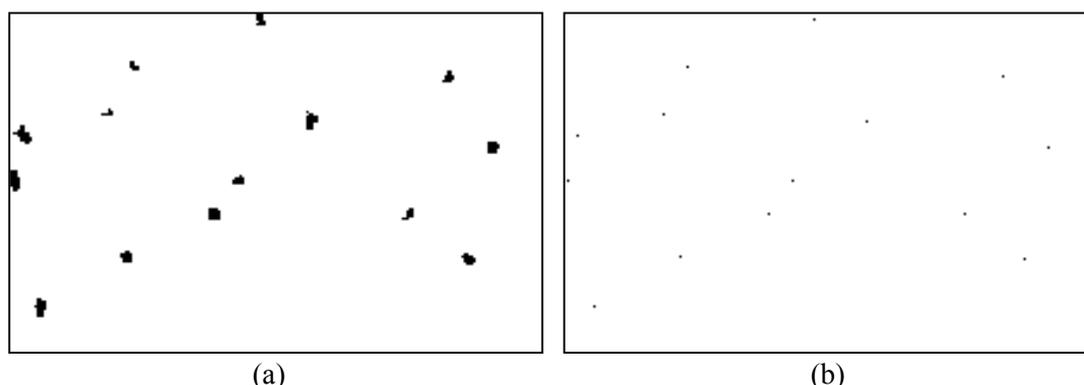


Figura 6.4 – (a) Imagem binarizada após a filtragem com o filtro de Gabor. (b) Imagem com os centros de cada uma das regiões conexas obtidas aplicando-se o algoritmo de rotulação em (a).

O módulo GNC consiste, portanto, em filtrar a imagem com o filtro de Gabor, binarizar a imagem com o limiar de corte, rotular a imagem binária e utilizar os centros de suas regiões como posições candidatas a serem minúcias.

Cada ponto extraído desta forma não indica que necessariamente existe uma minúcia em sua posição, mas que é provável haver uma minúcia próxima daquele pixel. Observe que não existe necessariamente uma minúcia, ou seja, por alguma razão (como presença de ruído) pode ser que uma região que não possui minúcia tenha uma resposta baixa no filtro de Gabor e no processo de binarização tenha sido rotulada como uma região candidata a ser minúcia.

Os pontos gerados pelo GNC são apenas aqueles contidos na área da imagem que contém a impressão digital, após ter sido extraída pelo segmentador proposto no Capítulo 5.

6.2 MVN (Módulo de Validação Neural)

Após a extração das posições candidatas a serem minúcias é necessário validá-las classificando-as como sendo fim-de-linha, bifurcação ou não-minúcia.

Para esta tarefa foram testados alguns modelos baseados em redes neurais que recebem como entrada um fragmento da imagem em torno do ponto candidato a minúcia e classifica-o como pertencendo a uma das 3 classes mencionadas anteriormente.

Cada minúcia tem associada a si a sua posição (x,y) dentro da imagem e um ângulo θ que indica a direção e o sentido da linha a qual ela pertence. Este ângulo é estimado projetando-se o vetor gradiente do pixel contra a direção local das linhas (JAIN, PANKANTI, 1997). O ângulo do vetor projetado é o ângulo da minúcia. A Figura 6.5 exhibe como este ângulo é calculado.

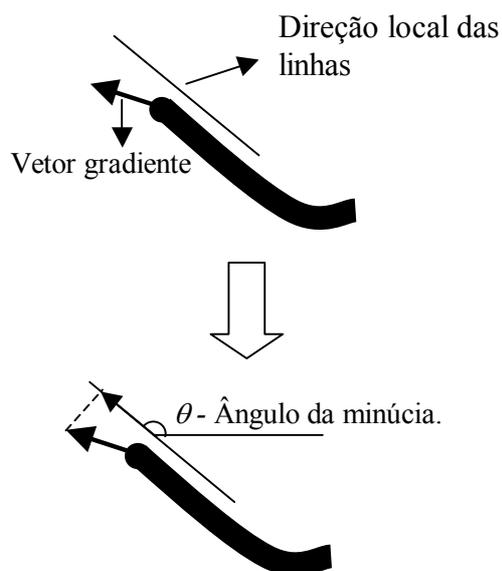


Figura 6.5 – Esta figura ilustra como é calculado o ângulo da minúcia.

Como mencionado anteriormente, o módulo de validação é um classificador que recebe como entrada um fragmento da imagem em torno do pixel candidato e classifica-o como pertencente a uma das classes mencionadas, no entanto, para que o MVN seja invariante a direção da minúcia, a extração deste fragmento é feita levando-se em conta esta direção.

Como o GNC filtra a imagem com o filtro de Gabor complexo, a parte real do filtro é guardada, pois ela corresponde à filtragem da imagem original pelo Gabor real que é utilizado para melhorar a qualidade da imagem. Portanto, a extração das características é feita em cima da imagem filtrada e não na imagem original.

As subseções seguintes exibem os tipos de extração de características testadas neste trabalho, que foram, o mapa de bits, o mapa de bits com correção de ângulo e o mapa de bits com correção de ângulo suavizado.

6.2.1 Mapa de Bits (MB)

O primeiro tipo de extração de minúcias foi o mais simples, que consiste em extrair uma imagem centralizada no pixel candidato rotacionado de acordo com o ângulo estimado da minúcia, como descrito na seção anterior (Figura 6.5). A largura e a altura da imagem extraída utilizada neste trabalho foram respectivamente de 27 e 17 pixels, o que corresponde a uma imagem de aproximadamente 1,37 mm x 0,86 mm. A Figura 6.6 exhibe como é feita a extração das características.

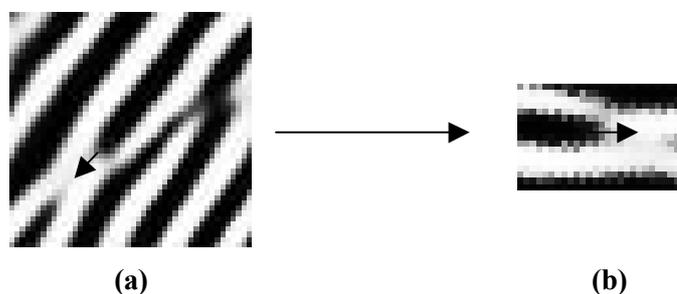


Figura 6.6 – (a) Fragmento de uma imagem de uma impressão digital filtrada com o filtro de Gabor, a seta indica a direção estimada de um ponto candidato a ser minúcia. (b) Vetor de características extraído, uma imagem de 27 x 17 pixels.

O vetor de características extraído desta forma elimina o problema da rotação, ou seja, minúcias que apareçam em várias direções diferentes serão apresentadas à rede aproximadamente da mesma forma.

As figuras 6.7 e 6.8 exibem respectivamente o mapa de bits de uma bifurcação e de uma região que não contém minúcia.

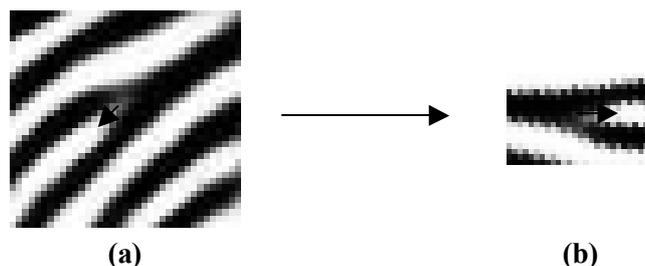


Figura 6.7 – (a) Fragmento de uma bifurcação, a seta indica a direção estimada da minúcia. (b) Vetor de características extraído, uma imagem de 27 x 17 pixels.

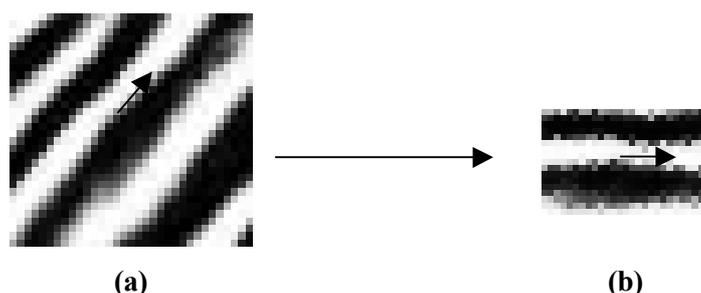


Figura 6.8 – (a) Fragmento de uma não-minúcia, a seta indica a direção estimada caso fosse uma minúcia. (b) Vetor de características extraído, uma imagem de 27 x 17 pixels.

O mapa de bits corresponde, portanto, a um vetor de características de $27 \times 17 = 459$ posições. Cada posição do vetor contém o valor do tom de cinza da imagem filtrada pelo filtro de Gabor Real. Para fins apenas de normalização, cada posição do vetor é dividida por 255, garantindo que cada dimensão varie entre 0 e 1. Daqui em diante este tipo de extração será chamada simplesmente de MB.

6.2.2 Mapa de Bits com Correção de Ângulo (MBCA)

Como visto na seção anterior, o MB consiste em extrair um retângulo de 27 por 17, centralizado no ponto candidato a ser minúcia e rotacionado do ângulo estimado. Esta extração funciona bem para a maioria das minúcias contidas na imagem, porém, para uma minoria de minúcias que se encontram em regiões curvadas como, por exemplo, o centro do dedo, esta estratégia não funciona tão bem. Para ilustrar esta situação observe a extração do mapa de bits para bifurcação da Figura 6.9.

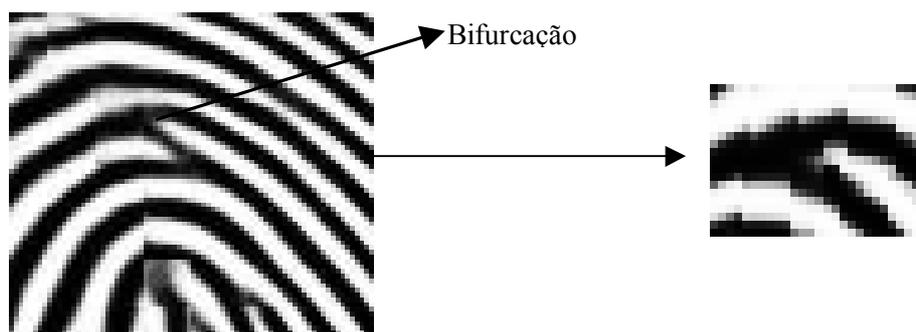


Figura 6.9 – Extração do mapa de bits de uma bifurcação que se encontra em uma região de curva. Observe que as linhas da bifurcação estão tortas com relação ao mapa de bits.

Para que a extração fique melhor para minúcias que se encontram nestas regiões, foi feita uma extração que utiliza uma imagem direcional e corrige o ângulo da extração a cada pixel que é varrido na imagem original. A imagem direcional pode ser aproveitada do módulo GNC, já que ela é utilizada para filtrar a imagem com o filtro de Gabor.

A Figura 6.10 exhibe como a imagem da Figura 6.9 fica com a correção de ângulo.



Figura 6.10 – (a) Mapa de bits extraído da bifurcação da imagem da Figura 6.9. (b) Mapa de bits com ângulo corrigido extraído da mesma bifurcação.

O mapa de bits com correção de ângulo também possui 459 posições, cada uma variando entre 0 e 1. Daqui em diante este tipo de extração será chamada de MBCA.

6.2.3 Mapa de Bits com Correção de Ângulo Suavizado (MBCAS)

O último tipo de extração de características utilizada explora o fato de que cada pixel do MBCA possui uma alta correlação com os seus pixels das colunas vizinhas, devido ao fato de que após a rotação, as linhas da impressão digital ficam posicionadas

horizontalmente, então dois pixels de colunas vizinhas possuem tons de cinza muito próximos.

Devido a esta alta correlação, foi testado uma extração de características que consiste em extrair a média de cada 3 pixels vizinhos de uma mesma linha, e aplicar esta idéia para todas as linhas. Portanto, como cada linha possui 27 pixels, serão geradas $27/3 = 9$ médias. A Figura 6.11 exibe uma linha e as médias geradas.

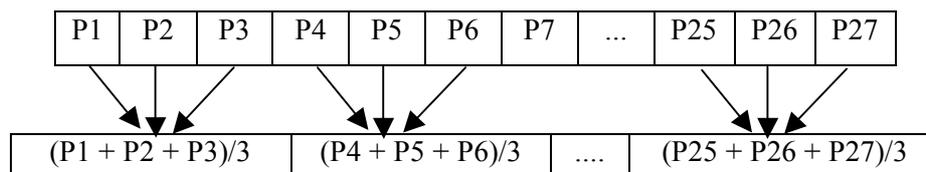


Figura 6.11 – A figura acima exibe uma linha de um MBCA com 27 posições. A figura abaixo exibe as 9 médias extraídas da linha.

O MBCAS, como será chamado este tipo de extração, consiste na extração dessas 9 médias para cada linha do MBCA, gerando portanto, $17 \times 9 = 153$ posições. Como cada posição do MBCA varia entre 0 e 1, o mesmo ocorre com as posições do MBCAS.

6.3 Testes e Resultados

Nesta seção são apresentados os experimentos e resultados feitos sobre o extrator de minúcias. Foram feitas análises em separado para os módulos GNC e MVN e a análise da performance geral sobre o extrator de minúcia.

O conjunto de teste é composto por 12 imagens obtidas do arquivo NIST (GARRIS, MCCABE, 2000). Entre as imagens existem aquelas de boa, má e péssima qualidade. As figuras 6.12, 6.13 e 6.14 exibem 3 imagens do conjunto de teste com qualidades respectivamente, boa, má e péssima.

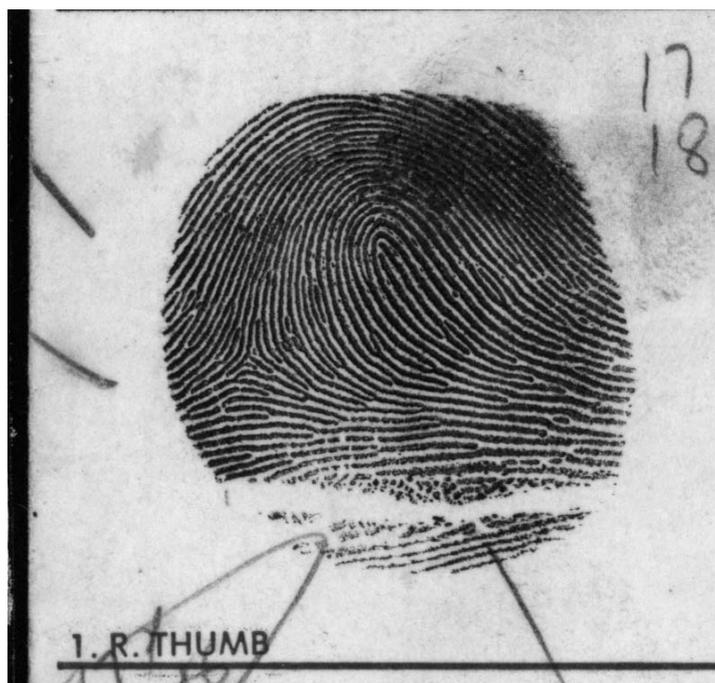


Figura 6.12 – Imagem obtida do arquivo NIST, código U295. Esta imagem possui boa qualidade, as linhas estão pouco falhadas e há um bom contraste entre linhas e fundo.

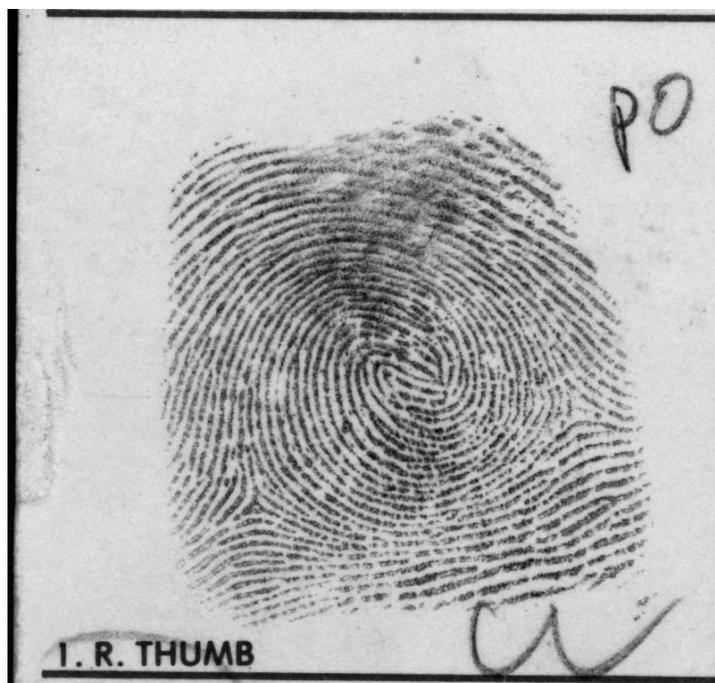


Figura 6.13 – Imagem de código U238 do arquivo NIST. Esta imagem é de má qualidade, pois possui linhas muito falhadas e apesar do contraste não ser muito baixo, ele está bem menor do que o da Figura 6.11.

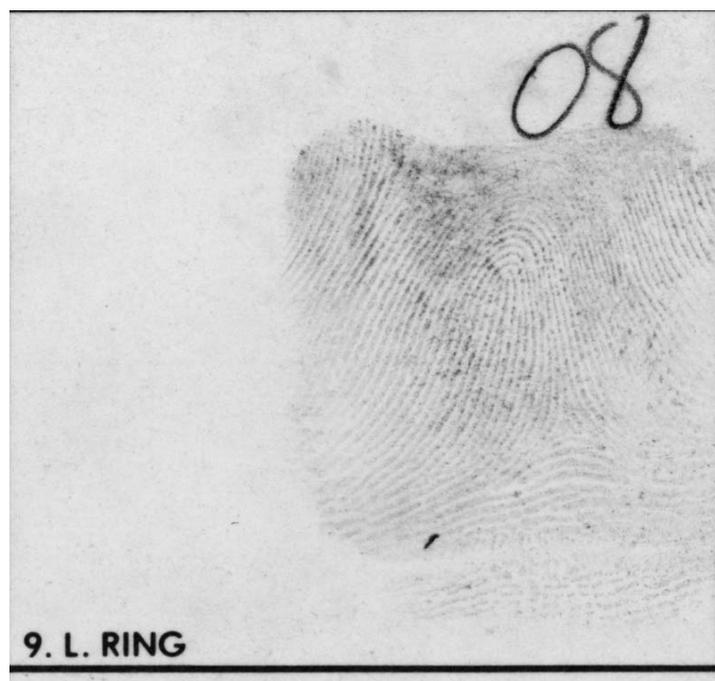


Figura 6.14 – Imagem de código G099 do arquivo NIST. Esta imagem é de péssima qualidade, pois o contraste é muito baixo e as linhas estão muito falhadas.

Os testes feitos sobre o MVN utilizam as extrações de características descritas na Seção 6.2, porém, é também testado o uso do PCA para redução da dimensão do vetor de entrada.

O restante desta seção está organizada da seguinte forma, a seção seguinte (6.3.1) apresenta uma descrição breve do PCA. As seções 6.3.2, 6.3.3 e 6.3.4 apresentam os resultados dos testes realizados utilizando a base de teste descrita acima, respectivamente sobre o módulo GNC, MVN e sobre o extrator de minúcias geral.

6.3.1 PCA

Esta seção faz uma descrição breve sobre o PCA, sem entrar em detalhes, apenas o suficiente para explicar como ele foi utilizado neste trabalho.

O PCA (Principal Component Analysis) (JOHNSON, WICHERN, 1992), consiste em uma transformação linear que é muito utilizada para a redução da dimensão de um vetor com perda controlada de informação. Na área de redes neurais o PCA é muito utilizado, pois ao reduzir a dimensão do vetor de entrada de uma rede neural, o

tempo de treinamento diminui e a probabilidade de se obter uma rede com maior poder de generalização aumenta.

Para descrever melhor como o PCA funciona, suponha o seguinte: cada dimensão do vetor de entrada pode ser visto como sendo uma variável aleatória (HOEL, PORT, STONE, 1978), onde cada amostra de uma dimensão de um vetor de entrada presente na base de treinamento representa uma observação de uma determinada variável aleatória.

Desta forma, a base de treinamento pode ser vista como sendo uma matriz A de M linhas por N colunas, onde N representa a dimensão do vetor de entrada e M o número de amostras de cada dimensão do vetor de entrada. Portanto, cada coluna j da matriz A contém M observações sobre a variável aleatória representada pela j -ésima dimensão do vetor de entrada. A Figura 6.15 ilustra a matriz A .

$$\begin{array}{c}
 \overbrace{\hspace{10em}}^{N - \text{Dimensão do vetor de entrada}} \\
 \left[\begin{array}{cccccc}
 A_{1,1} & A_{1,2} & A_{1,3} & A_{1,4} & \dots & A_{1,N-1} & A_{1,N} \\
 A_{2,1} & A_{2,2} & A_{2,3} & A_{2,4} & \dots & A_{2,N-1} & A_{2,N} \\
 \vdots & & & & & & \\
 A_{M,1} & A_{M,2} & A_{M,3} & A_{M,4} & \dots & A_{M,N-1} & A_{M,N}
 \end{array} \right]
 \end{array}
 \quad
 \begin{array}{l}
 M - \text{Número de amostras de cada} \\
 \text{dimensão de entrada.}
 \end{array}$$

Figura 6.15 – Matriz de treinamento de uma rede neural. Possui N colunas, que representam cada dimensão de entrada, e M linhas, que representam as observações sobre cada variável de entrada.

A quantidade de informação que a rede neural necessita para fazer sua discriminação está distribuída, é claro, entre as variáveis de entrada. Porém, a quantidade de informação nem sempre está igualmente distribuída, podendo estar mais concentrada em algumas variáveis do que em outras.

Uma medida utilizada para se saber a quantidade de informação contida em uma variável é a sua variância. Portanto, variáveis com variância maior possuem mais informação do que aquelas de variância menor.

Com isso, uma forma simples de reduzir a dimensão do vetor de entrada seria eliminar aquelas variáveis que possuem variância menor do que determinado limiar. Porém, existe o grau de dependência entre variáveis, ou seja, uma variável quando analisada isoladamente pode conter pouca informação, porém, se analisada em conjunto

com outras ela pode conter muita informação. Uma medida para se saber o grau de dependência entre duas variáveis é a covariância. As definições de variância e covariância podem ser encontradas em (HOEL, PORT, STONE, 1978).

O PCA é uma transformação linear que tem como objetivo criar um novo conjunto de variáveis em que cada uma delas é uma combinação linear das variáveis originais. No entanto, esta transformação é tal que a covariância entre quaisquer duas variáveis do novo conjunto é zero. Isso significa que todas as variáveis são independentes e, portanto, pode-se fazer a redução simples de se eliminar as variáveis que possuam variância menor do que determinado limiar.

Neste trabalho, o PCA foi utilizado da seguinte forma, toda a variável k que possua variância relativa VR_k abaixo de um determinado limiar ν é eliminada. Os valores de ν são exibidos na Seção 6.3.3, que exibe os resultados do módulo de validação. A equação 6.1 exibe o cálculo da variância relativa VR_k .

$$VR_k = \frac{Var_k}{\sum_{i=1}^N Var_i} \quad (eq. 6.1)$$

Onde: N – dimensão do vetor de entrada;

Var_n – Variância da variável n .

6.3.2 Testes e Resultados do GNC

Como visto na Seção 6.1, o GNC gera a lista de pontos candidatos a minúcias baseado no resultado da filtragem da imagem de entrada pelo filtro de Gabor Complexo. Como mencionado também naquela mesma seção, os pontos candidatos indicam uma possível localização próxima a uma minúcia, ou seja, a posição não é exata.

Portanto, para se medir a qualidade da lista de minúcias candidatas gerada, é necessário saber, dada uma imagem, quantas minúcias reais estão próximas de alguma minúcia candidata e quantas minúcias candidatas espúrias são geradas, ou seja, aquelas candidatas que não possuem nenhuma minúcia real perto de si. Para se melhor estabelecer essas quantidades considere o seguinte:

Seja mc o conjunto de minúcias candidatas geradas pelo GNC a partir de uma imagem I , e mr o conjunto de minúcias reais extraídas da mesma imagem I por um perito em impressões digitais. Será chamado de mcr o conjunto de minúcias candidatas reais, que é o subconjunto de minúcias de mc que estejam a uma distância menor que um determinado valor de alguma minúcia de mr . Portanto, mcr pode ser definido pela equação 6.2 a seguir:

$$mcr = \left\{ (x, y) \in mc / \exists_{(x', y')} \left\{ (x', y') \in mr \wedge \sqrt{(x - x')^2 + (y - y')^2} \leq D_{max} \right\} \right\} \quad (eq. 6.2)$$

O valor D_{max} da equação anterior determina o raio da região que será analisada pelo módulo de validação (MVN). Portanto, deseja-se que D_{max} seja o mais baixo possível, diminuindo o trabalho de MVN, porém o valor não pode ser muito baixo, pois desta forma se estaria exigindo uma precisão alta da localização da minúcia por parte do filtro de Gabor.

O valor para D_{max} escolhido neste trabalho é proporcional à largura das linhas da impressão digital, pois quanto mais larga a linha, maior é a região escura em torno da minúcia e, portanto, existe uma maior probabilidade da posição do centro da região estar mais distante da posição da minúcia real.

Como a largura das linhas varia aproximadamente entre 0.25 e 0.5 mm, foi escolhido para D_{max} o dobro da largura máxima esperada, ou seja, $D_{max} = 1$ mm. Como as imagens utilizadas neste trabalho estão armazenadas em 500 ppp (pontos por polegada) de resolução, e cada polegada equivale a 25.4 mm, o valor de D_{max} em pixels é dado por, $D_{max} = \lceil (1 \text{ mm}) \cdot (500 \text{ pixels} / \text{pol}) / (25.4 \text{ mm} / \text{pol}) \rceil = 19,68 = 20 \text{ pixels}$.

Finalmente, para se analisar a qualidade da extração pelo filtro de Gabor são estabelecidas as seguintes quantidades, $pmcr$ (Percentual de Minúcias Candidatas Reais) e $pmcf$ (Percentual de Minúcias Candidatas Falsas), que são definidas pelas equações 6.3 e 6.4 respectivamente.

$$pmcr = 100 \cdot \frac{|mcr|}{|mr|} \quad (eq. 6.3)$$

$$pmcf = 100 \cdot \frac{|mc - mcr|}{|mr|} \quad (eq. 6.4)$$

Observe nas equações 6.3 e 6.4 que $pmcr$ e $pmcf$ não são complementares, ou seja, $pmcr \neq 100 - pmcf$. Para ilustrar esta afirmação considere o seguinte exemplo, suponha que mr possua 40 minúcias, ou seja, $|mr| = 40$ e $|mc| = 70$. Suponha que apenas 20 das minúcias de mc coincidam com alguma de mr , logo $|mcr| = 20$. Pelas equações anteriores tem-se que $pmcr = 100 \cdot \frac{20}{40} = 50$ e $pmcf = 100 \cdot \frac{70-20}{40} = 125$. Neste exemplo, o filtro de Gabor acertou 50% das minúcias e gerou 125% de minúcias falsas.

O que se deseja, portanto, é que o módulo GNC gere o maior valor para $pmcr$ e o menor para $pmcf$. Cabe lembrar que estes valores dependem do limiar de corte utilizado no processo de binarização, por isso os testes foram feitos com 3 valores para o limiar de corte L .

Para se diminuir o número de minúcias falsas geradas pelo GNC, após a rotulação são eliminadas as regiões com uma área maior do que determinado tamanho, que neste trabalho é de 100 pixels quadrados.

Os testes do GNC foram feitos utilizando-se a base de teste definida na Seção 6.3 e fazendo-se o limiar L sendo 50, 100 e 150. As médias de $pmcr$ e $pmcf$ para cada valor são exibidas na Tabela 6.1 a seguir.

	50	100	150
$pmcr$	95.6268%	96.4786%	99.6956%
$pmcf$	136.2083%	237.3628%	11546.5408%

Tabela 6.1 – Resultados do GNC testados com diferentes valores para o limiar de corte L .

Como pode ser observado na Tabela 6.1, quanto maior o limiar de corte, maiores são os valores de $pmcr$ e $pmcf$, porém o valor de $pmcf$ cresce muito mais rápido com relação ao valor do limiar do que $pmcr$. Isso ocorre devido ao fato de que quanto maior o limiar mais regiões se tornarão pretas após a binarização, portanto, maiores são as chances de acertar e de errar uma minúcia, porém, como a quantidade de regiões que não possuem minúcias é maior do que a quantidade das que possuem, $pmcf$ cresce mais rapidamente.

Devido aos resultados apresentados na Tabela 6.1, foi escolhido neste trabalho utilizar o limiar $L=50$, pois é o que apresenta a melhor razão entre $pcmr$ e $pmcf$.

6.3.3 Testes e Resultados do MVN

Como os pontos candidatos gerados pelo módulo GNC podem estar a uma distância de até 20 pixels de uma minúcia verdadeira, o Módulo de Validação deve percorrer uma vizinhança em torno de cada ponto candidato em busca de possíveis minúcias que estejam a uma distância de até 20 pixels do ponto candidato. Neste trabalho escolheu-se percorrer esta região da seguinte forma, para cada ponto candidato de coordenada (x,y) são percorridos 4 blocos de 20 pixels de largura que são determinados pelas coordenadas $[x-20:x, y-20:y]$, $[x:x+20, y-20:y]$, $[x-20:x, y:y+20]$ e $[x:x+20, y:y+20]$. A Figura 6.16 exhibe estes 4 blocos.

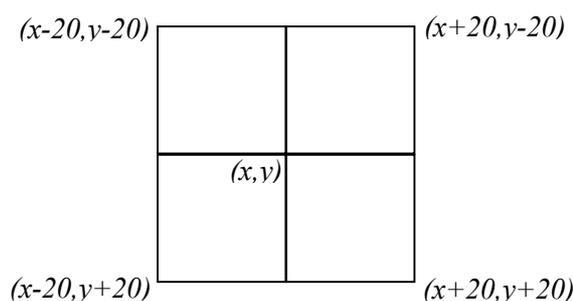


Figura 6.16 – Os 4 blocos que são percorridos para cada ponto candidato de coordenada (x,y) .

Para cada pixel de cada um destes 4 blocos, é extraído um vetor de características que é apresentado a uma rede neural que o classifica como sendo fim-de-linha, bifurcação ou não-minúcia.

Serão testados os três tipos de extração de características exibidos nas seções 6.2.1, 6.2.2 e 6.2.3.

Como mais de um pixel pode ser classificado como sendo uma minúcia, para cada bloco é considerado somente aquele pixel que teve o maior grau de confiança. Este grau de confiança depende do tipo de rede utilizada e será melhor explicado à frente.

Depois da classificação neural, é feito mais um pós-processamento que visa remover as minúcias espúrias geradas. Este processamento é feito da seguinte forma: se

duas minúcias estiverem a uma distância menor do que um valor pré-estipulado, é feito o seguinte teste: se os ângulos das minúcias tiverem uma diferença maior que 90° então ambas as minúcias são removidas, caso contrário, é removida apenas aquela que possui o menor grau de confiança. Neste trabalho esta regra é aplicada somente nas minúcias que possuem uma distância menor ou igual a 10 pixels (0.5 mm).

Portanto, do método descrito pode-se observar que cada candidato a minúcia pode gerar até 4 minúcias (uma para cada bloco).

Para se fazer os testes foram utilizadas as 12 imagens descritas na Seção 6.3, porém para o treinamento das redes foram utilizadas outras 29 imagens, diferentes das utilizadas para teste, para se avaliar o grau de generalização da rede.

A base de treinamento está organizada da seguinte forma:

- Base de Treinamento: possui 3194 padrões sendo 957 exemplos de fins-de-linha, 793 padrões de bifurcações e 1444 exemplos de *não-minúcias*;

- Base de Teste: possui 797 padrões distribuídos como 238 *fins-de-linha*, 198 bifurcações e 361 não-minúcias;

- Base de Validação: possui as mesmas quantidades que a Base de Teste.

As redes testadas são do tipo MLP, que foram treinadas utilizando-se quatro arquiteturas de redes diferentes, todas com apenas uma camada escondida, variando apenas a quantidade de neurônios nesta camada. As 4 arquiteturas são as seguintes:

Seja N – dimensão do vetor de entrada, que depende do vetor de característica utilizado.

Arquiteturas de redes:

1) $N \times 5 \times 3$

2) $N \times 10 \times 3$

3) $N \times 15 \times 3$

4) $N \times 40 \times 3$.

As 4 arquiteturas exibidas acima são treinadas utilizando-se a mesma base de treinamento, validação e teste, porém, com os 3 diferentes tipos de extração de

características. Portanto, como são 4 arquiteturas de redes e 3 tipos de vetor de características, são gerados no final 12 resultados diferentes que devem ser analisados.

Porém, para as extrações do tipo MB e MBCA foram também testados a utilização do PCA com 3 fatores de corte (Seção 6.3.1). E a extração do tipo MBCAS foi testada com PCA utilizando dois fatores. Desta forma, devem ser analisados 44 resultados. A Tabela 6.2 exibe todas as variações da base de entrada com relação ao tipo de extração e a utilização do PCA. A tabela também exibe o nome dado a cada variação, que serão utilizados daqui para frente a fim de simplificar as referências a cada tipo.

Nome de referência	Tipo de extração	PCA	Dimensão de entrada
B_MB	MB	Sem PCA	459
B_MB_PCA_01	MB	PCA com corte 10^{-3}	46
B_MB_PCA_02	MB	PCA com corte 3×10^{-4}	123
B_MB_PCA_03	MB	PCA com corte 10^{-4}	290
B_MBCA	MBCA	Sem PCA	459
B_MBCA_PCA_01	MBCA	PCA com corte 10^{-3}	46
B_MBCA_PCA_02	MBCA	PCA com corte 3×10^{-4}	113
B_MBCA_PCA_03	MBCA	PCA com corte 10^{-4}	310
B_MBCAS	MBCAS	Sem PCA	153
B_MBCAS_PCA_01	MBCAS	PCA com corte 10^{-3}	44
B_MBCAS_PCA_02	MBCAS	PCA com corte 4×10^{-4}	72

Tabela 6.2 – Lista das combinações de extração de características e uso do PCA. Cada combinação possui um nome, totalizando 11 combinações diferentes.

Cada base de dados apresentada na Tabela 6.2 é subdividida em treinamento, teste e validação como descrito anteriormente.

As 44 redes testadas foram treinadas utilizando o algoritmo de treinamento Resilient Backpropagation, na plataforma MatLab 6.1, MathWorks Inc.

Como o número de redes é alto, serão apresentados os resultados de apenas 3 redes, uma para cada tipo de extração de características. As redes escolhidas para cada

tipo são aquelas que obtiveram o melhor índice de acerto de classificação, somando-se os acertos da base de treino, teste e validação.

Para a extração do tipo MB a melhor rede obtida foi aquela que utiliza a base de dados sem PCA e 40 neurônios na camada escondida. As tabelas 6.3, 6.4 e 6.5 exibem respectivamente as matrizes de confusão das bases de treinamento, validação e teste desta rede.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	947	0	15	-
	Bifurcação	0	782	12	-
	Não-minúcia	10	11	1417	-
	Acerto (%)	98,96%	98,61%	98,13%	98,5%

Tabela 6.3 – Matriz de confusão da base de treinamento sobre a base B_MB, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 98.5%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	225	0	3	-
	Bifurcação	0	188	4	-
	Não-minúcia	13	10	354	-
	Acerto (%)	94,54%	94,95%	98,06%	96,4%

Tabela 6.4 – Matriz de confusão da base de validação sobre a base B_MB, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 96.24%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	226	0	6	-
	Bifurcação	0	189	7	-
	Não-minúcia	12	9	348	-
	Acerto (%)	94,96%	95,45%	96,4%	95,73%

Tabela 6.5 – Matriz de confusão da base de teste sobre a base B_MB, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 95.73%.

Para a extração do tipo MBCA a melhor rede obtida foi também a que utiliza a base de dados sem PCA e 40 neurônios na camada escondida. As tabelas 6.6, 6.7 e 6.8 exibem respectivamente as matrizes de confusão das bases de treinamento, validação e teste desta rede.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	937	0	16	-
	Bifurcação	0	784	13	-
	Não-minúcia	20	9	1415	-
	Acerto (%)	97,91%	98,87%	97,99%	98,18%

Tabela 6.6 – Matriz de confusão da base de treinamento sobre a base B_MBCA, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 98.18%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	229	0	3	-
	Bifurcação	0	187	5	-
	Não-minúcia	9	11	353	-
	Acerto (%)	96,22%	94,44%	97,78%	96,49%

Tabela 6.7 – Matriz de confusão da base de validação sobre a base B_MBCA, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 96.49%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	230	0	7	-
	Bifurcação	0	184	7	-
	Não-minúcia	8	14	347	-
	Acerto (%)	96,64%	92,93%	96,12%	95,48%

Tabela 6.8 – Matriz de confusão da base de teste sobre a base B_MBCA, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 95.48%.

Para a extração do tipo MBCAS a melhor rede obtida foi também a que utiliza a base de dados sem PCA e 40 neurônios na camada escondida. As tabelas 6.9, 6.10 e 6.11 exibem respectivamente as matrizes de confusão das bases de treinamento, validação e teste desta rede.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	940	0	25	-
	Bifurcação	0	786	15	-
	Não-minúcia	17	7	1404	-
	Acerto (%)	98,22%	99,11%	97,23%	98%

Tabela 6.9 – Matriz de confusão da base de treinamento sobre a base B_MBCAS, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 98%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	232	0	6	-
	Bifurcação	0	188	6	-
	Não-minúcia	6	10	349	-
	Acerto (%)	97,48%	94,95%	96,68%	96,49%

Tabela 6.10 – Matriz de confusão da base de validação sobre a base B_MBCAS, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 96.49%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	231	0	9	-
	Bifurcação	0	189	9	-
	Não-minúcia	7	9	343	-
	Acerto (%)	97,06%	95,45%	95,01%	95,73%

Tabela 6.11 – Matriz de confusão da base de teste sobre a base B_MBCAS, obtida pela rede de arquitetura 459x40x3. O índice de acerto geral foi de 95.73%.

Além destas redes do tipo MLP, foi também testada a rede do tipo Fuzzy-ARTMAP (CARPENTER, GROSSBERG, MARKUZON, REYNOLDS, ROSEN, 1992). A Fuzzy-ARTMAP, ou FAM, é uma rede auto-organizável com treinamento supervisionado. A FAM recebe como entrada valores que variam entre 0 e 1, que é o caso dos vetores de entrada utilizados neste trabalho.

A FAM foi testada apenas para a base B_MBCAS, pois para que o treinamento desta rede seja eficiente é necessário utilizar como entrada o vetor de entrada e seu complemento fuzzy, ou seja, o vetor de entrada passa a ter o dobro do tamanho. Como a base B_MBCAS corresponde a um vetor de entrada de 153 posições, significa que a FAM receberá como entrada um vetor de 306 posições. Com as outras bases o vetor de entrada ficaria muito grande.

A FAM possui alguns parâmetros para o treinamento, entre os mais importantes estão a taxa de aprendizado β e o limiar de vigilância ρ , ambos podem assumir valores entre 0 e 1. Foram treinadas 30 redes FAM variando-se esses dois parâmetros.

A melhor rede FAM obtida foi a rede treinada com $\rho = 0.2$ e $\beta = 0.5$. As tabelas 6.12, 6.13 e 6.14 exibem o desempenho da melhor rede FAM. As redes FAM não utilizam base de validação ou de teste durante o treinamento, mas mesmo assim os resultados desta rede sobre estas bases são exibidos nas tabelas seguintes.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	911	0	32	-
	Bifurcação	0	773	38	-
	Não-minúcia	46	20	1374	-
	Acerto (%)	95,19%	97,48%	95,15%	95,74%

Tabela 6.12 – Matriz de confusão da base de treinamento sobre a base B_MBCAS, obtida pela rede FAM com $\rho = 0.2$ e $\beta = 0.5$. O índice de acerto geral foi de 95.74%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	229	0	6	-
	Bifurcação	0	190	13	-
	Não-minúcia	9	8	342	-
	Acerto (%)	96,22%	95,96%	94,74%	95,48%

Tabela 6.13 – Matriz de confusão da base de validação sobre a base B_MBCAS, obtida pela rede FAM com $\rho = 0.2$ e $\beta = 0.5$. O índice de acerto geral foi de 95.48%.

		Classe desejada			
		Fim-de-linha	Bifurcação	Não-minúcia	Geral
Classe estimada	Fim-de-linha	228	0	11	-
	Bifurcação	0	191	14	-
	Não-minúcia	10	7	336	-
	Acerto (%)	95,8%	96,46%	93,07%	94,73%

Tabela 6.14 – Matriz de confusão da base de teste sobre a base B_MBCAS, obtida pela rede FAM com $\rho = 0.2$ e $\beta = 0.5$. O índice de acerto geral foi de 94.73%.

6.3.4 Testes com as Imagens do NIST

Até o momento, foram apresentadas 4 redes e os resultados de sua eficiência com relação as bases de treinamento, teste e validação obtidas das 29 imagens mencionadas no início desta seção. Neste momento, resta testar a eficiência das redes com relação à outra base de teste descrita na Seção 6.3, que é formada por 12 imagens do arquivo NIST.

Porém, antes será lembrado, neste ponto, como o MVN será usado na extração de minúcias de uma imagem. A seguir segue um fluxo que descreve o funcionamento básico do MVN:

- 1) Aplica-se o GNC sobre a imagem, gerando uma lista de minúcias candidatas mc ;
- 2) Para cada elemento de posição (x,y) de mc , execute o passo 3 para todos os pixels de 4 blocos ao redor de (x,y) como dito no início desta seção (Figura 6.15);
- 3) Para cada pixel com posição (x',y') de cada bloco do passo anterior extraia um vetor de características;
- 4) Submeta o vetor de características à rede, caso a rede o classifique como sendo um fim-de-linha ou uma bifurcação, armazene a coordenada do pixel correspondente em uma lista de minúcias;
- 5) Se dentro de mais de um bloco houver mais de uma minúcia, fica-se apenas com a minúcia de maior grau de confiança (será explicado adiante), eliminando-se as demais;
- 6) Para cada par de minúcias geradas com distância menor do que 10 pixels, faça o seguinte: se o ângulo entre as minúcias for menor do que 90° fica-se com a que tiver maior grau de confiança e elimina-se a outra, senão elimina-se as duas minúcias.

Da seqüência de passos acima, pode-se observar que a extração de minúcias começa no passo 4. No passo 5 é utilizado um grau de confiança que depende do tipo de rede utilizada, no caso da MLP, o grau de confiança é o valor do disparo do neurônio da rede para a minúcia correspondente, e no caso da rede FAM, o grau de confiança é o

grau de inclusão do vetor de entrada no conjunto fuzzy correspondente, gerado pela rede durante o treinamento.

O passo 6 é um pós-processamento que visa eliminar falsas minúcias geradas. Minúcias muito próximas provavelmente correspondem a uma mesma minúcia que foi marcada duas vezes, ou devido ao fato da região da imagem estar com muito ruído várias minúcias espúrias podem ser geradas. Se ocorrer o primeiro caso, é muito provável que as minúcias geradas tenham um ângulo semelhante, porém, no segundo caso é provável que as minúcias apontem para direções bem diferentes. Por isso, foi utilizada a heurística de se considerar como sendo o primeiro caso quando o ângulo entre as minúcias for menor do que 90° e considerar como sendo o segundo caso, caso ocorra o contrário.

Os arquivos NIST utilizados possuem associados a cada imagem um gabarito de minúcias extraídas manualmente por peritos em impressões digitais, porém, os peritos não fizeram diferenciação entre fim-de-linha e bifurcação, eles apenas marcaram a presença de uma minúcia e a sua direção. Como a marcação foi manual, a posição e as direções das minúcias não é muito precisa, adotou-se para se comparar o MVN com as marcações do perito, a seguinte estratégia: toda a minúcia gerada pelo MVN será considerada verdadeira se existir uma minúcia marcada pelo perito a uma distância menor ou igual a um valor DR_{max} e o cosseno do menor ângulo entre as direções das minúcias for maior ou igual a um valor C_{min} . A equação 6.5 exhibe a fórmula que define a função lógica *Genuína*, que retorna *verdadeiro* quando a minúcia é genuína, e *falso* caso contrário.

$$Genuína(x, y, \theta) = \exists_{(x', y', \alpha)} \{ (x', y', \alpha) \in mr \wedge \sqrt{(x - x')^2 + (y - y')^2} \leq DR_{max} \wedge \cos(\min(|\theta - \alpha|, 360^\circ - |\theta - \alpha|)) \geq C_{min} \} \quad (eq. 6.5)$$

Onde: (x, y, θ) – coordenadas e ângulo de uma possível minúcia.

mr – lista de minúcias reais, geradas pelo perito.

Os testes sobre o MVN foram feitos utilizando-se a função acima para validar cada minúcia detectada, utilizando-se os valores $DR_{Max} = 10 \text{ pixels}$ e $C_{min} = 0.9$. Para

avaliar os resultados, foram computados 4 valores para as 12 imagens do conjunto de teste, que são os percentuais médios de:

- minúcias corretamente detectadas: são os pontos gerados pelo GNC que estão próximos de uma minúcia verdadeira e foram corretamente detectados pelo MVN;
- minúcias erroneamente detectadas: são os pontos que não estão próximos de nenhuma minúcia, mas o MVN classificou-os incorretamente como sendo minúcias genuínas (falsa aceitação);
- minúcias corretamente rejeitadas: são os pontos do GNC que não correspondem a minúcias e foram corretamente rejeitados pelo MVN;
- minúcias erroneamente rejeitadas: são os pontos que estavam próximos a alguma minúcia e foram incorretamente rejeitados pelo MVN (falsa rejeição).

A base de minúcias dos peritos é utilizada para validar as minúcias, porém os percentuais acima são feitos considerando os pontos gerados pelo GNC, pois nesta seção o foco é avaliar a eficiência apenas do MVN. Se os percentuais fossem comparados diretamente com a base de minúcias dos peritos, os percentuais estariam incluindo os erros gerados pelo GNC, pois este módulo inclui erros de detecção como pode ser visto na Seção 6.3.2.

As tabelas 6.15, 6.16, 6.17 e 6.18 exibem as matrizes de confusão percentual do MVN utilizando-se respectivamente, a rede MLP com base B_MB de arquitetura 459x40x3, a rede MLP com base B_MBCA de arquitetura 459x40x3, a rede MLP com base B_MBCAS de arquitetura 459x40x3 e a rede FAM com base B_MBCAS com $\rho = 0.2$ e $\beta = 0.5$. As matrizes de confusão possuem 4 posições, cada uma correspondendo a um dos 4 percentuais descritos anteriormente.

Classe desejada

		Classe desejada	
		Minúcia	Não-minúcia
Classe estimada	Minúcia	78,13%	28,39%
	Não-minúcia	21,87%	71,61%

Tabela 6.15 – Matriz de confusão média do MVN utilizando a rede MLP com arquitetura 459x40x3 treinada com a base B_MB. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.

		Classe desejada	
		Minúcia	Não-minúcia
Classe estimada	Minúcia	78,81%	28,31%
	Não-minúcia	21,19%	71,69%

Tabela 6.16 – Matriz de confusão média do MVN utilizando a rede MLP com arquitetura 459x40x3 treinada com a base B_MBCA. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.

		Classe desejada	
		Minúcia	Não-minúcia
Classe estimada	Minúcia	78,3%	27,61%
	Não-minúcia	21,7%	72,39%

Tabela 6.17 – Matriz de confusão média do MVN utilizando a rede MLP com arquitetura 459x40x3 treinada com a base B_MBCAS. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.

		Classe desejada	
		Minúcia	Não-minúcia
Classe estimada	Minúcia	81,73%	39,03%
	Não-minúcia	18,27%	60,97%

Tabela 6.18 – Matriz de confusão média do MVN utilizando a rede FAM com $\rho = 0.2$ e $\beta = 0.5$, treinada com a base B_MBCAS. Os testes foram feitos em cima das 12 imagens da base de teste descrita na Seção 6.3.

6.3.5 Resultados do Extrator de Minúcias

Nesta seção é analisada a eficiência final do extrator de minúcias, ou seja, será analisada a eficiência do conjunto formado pelo GNC e MVN. Os testes aqui são feitos utilizando-se as mesmas 12 imagens do conjunto de teste (Seção 6.3), no entanto, as medidas de eficiência utilizadas serão o *pmv* (Percentual de Minúcias Verdadeiras) e o

pmf (Percentual de Minúcias Falsas), que são medidas geralmente utilizadas para se medir a qualidade de um extrator de minúcias.

Os testes são feitos utilizando-se 4 tipos de MVN diferentes, que utilizam, cada um, uma das 4 melhores redes exibidas na seção anterior. Os MVN's serão identificados por nomes para facilitar a sua identificação, a Tabela 6.19 exibe os nomes e a descrição de cada MVN utilizado.

Nome	Rede	Base de utilizada para o treinamento da rede
MVN01	MLP 459x40x3	MB
MVN02	MLP 459x40x3	MBCA
MVN03	MLP 459x40x3	MBCAS
MVN04	FAM com $\rho = 0.2$ e $\beta = 0.5$	MBCAS

Tabela 6.19 – Os tipos de MVN utilizados para testar o desempenho do extrator de minúcias. As redes utilizadas são as melhores destacadas na seção anterior.

Os valores médios obtidos para *pmv* e *pmf* para cada um dos MVN's utilizados são exibidos na Tabela 6.20.

MVN utilizado	<i>pmv</i>	<i>pmf</i>
MVN01	74,86%	38,09%
MVN02	75,55%	38,41%
MVN03	75,09%	37,19%
MVN04	78,26%	50,33%

Tabela 6.20 – Percentuais médios de minúcias corretamente encontradas (*pmv*) e de minúcias falsas geradas (*pmf*), para cada tipo de MVN testado.

Observe da Tabela acima que *pmv* e *pmf* não são complementares, ou seja, $pmv + pmf \neq 100$. A medida *pmv* indica o percentual de minúcias verdadeiras que foram identificadas pelo extrator, enquanto que *pmf* é o percentual de minúcias detectadas pelo extrator que não correspondem a minúcias reais. Portanto, elas não são medidas complementares, pois, por exemplo, o extrator pode detectar todas as minúcias reais e gerar falsas minúcias, ou seja, neste caso *pmv* será 100% e *pmf* diferente de zero.

Como dito na Seção 6.3 as imagens que compõem a base de teste possuem qualidades diferentes, entre elas há os exemplos das imagens de código U295, U328 e G099 (estes códigos são utilizados para identificar as imagens dentro do arquivo NIST), que correspondem a imagens com qualidades respectivamente, boa, má e péssima.

As tabelas 6.21, 6.22 e 6.23 apresentam a performance do extrator de minúcias individualmente para cada uma delas, utilizando-se cada um dos 4 MVN's.

MVN utilizado	<i>pmv</i>	<i>pmf</i>
MVN01	93 / 107 (86,92%)	19 / 107 (17,76%)
MVN02	94 / 107 (87,85%)	19 / 107 (17,76%)
MVN03	95 / 107 (88,79%)	18 / 107 (16,82%)
MVN04	95 / 107 (88,79%)	32 / 107 (29,91%)

Tabela 6.21 – Valores percentuais e absolutos de minúcias corretamente encontradas (*pmv*) e de minúcias falsas geradas (*pmf*), para cada tipo de MVN testado contra a imagem U295, que possui boa qualidade e 107 minúcias reais.

MVN utilizado	<i>pmv</i>	<i>pmf</i>
MVN01	75 / 97 (77,32%)	28 / 97 (28,87%)
MVN02	76 / 97 (78,35%)	30 / 97 (30,93%)
MVN03	75 / 97 (77,32%)	28 / 97 (28,87%)
MVN04	80 / 97 (82,47%)	40 / 97 (41,24%)

Tabela 6.22 – Valores percentuais e absolutos de minúcias corretamente encontradas (*pmv*) e de minúcias falsas geradas (*pmf*), para cada tipo de MVN testado contra a imagem U238, que possui má qualidade e 97 minúcias reais.

MVN utilizado	<i>pmv</i>	<i>pmf</i>
MVN01	27 / 55 (49,09%)	39 / 55 (70,91%)
MVN02	26 / 55 (47,27%)	41 / 55 (74,55%)
MVN03	25 / 55 (45,45%)	38 / 55 (69,09%)
MVN04	33 / 55 (60%)	52 / 55 (94,55%)

Tabela 6.23 – Valores percentuais e absolutos de minúcias corretamente encontradas (*pmv*) e de minúcias falsas geradas (*pmf*), para cada tipo de MVN testado contra a imagem G099, que possui péssima qualidade e 55 minúcias reais.

Como dito no Capítulo 3, as minúcias geradas por um extrator de minúcias são utilizadas por um comparador para a identificação de impressões digitais. Quanto maior o número de falsas minúcias geradas por um extrator maior a probabilidade de ocorrer uma falsa correspondência (*FM* – False Match). Para se estimar o valor de *PFM* (Probabilidade de ocorrer um Falso Match entre dois conjuntos de minúcias) para um sistema utilizando o extrator proposto, será utilizado o modelo proposto em (MALTONI, MAIO, JAIN, PRABHAKAR, 2003). De acordo com este modelo a probabilidade de uma falsa correspondência é dada pela equação 6.6.

$$PFM = \sum_{\rho=q}^{\min(m,n)} \left(\frac{\binom{m}{\rho} \binom{M-m}{n-\rho}}{\binom{M}{n}} \times \binom{\rho}{q} L^q (1-L)^{\rho-q} \right) \quad (eq. 6.6)$$

Os parâmetros da eq. 6.6 são listados abaixo:

- q – número de minúcias genuínas extraídas pelo extrator;
- m – número de minúcias extraídas pelo extrator (genuínas ou não);
- n – número de minúcias presente no conjunto extraído pelos peritos;
- L – probabilidade de duas minúcias possuírem ângulo menor ou igual a um determinado valor;
- M – inteiro que melhor aproxima a razão da área de interseção entre duas impressões digitais que forem comparadas pelo comparador de minúcias, e a área de tolerância que é dada por $C = \pi r^2$, onde r é o raio de tolerância que neste caso é de 10 pixels.

Os valores de q , m e n podem ser estimados das imagens de teste, porém para L e M serão utilizados os valores estimados em (MALTONI, MAIO, JAIN, PRABHAKAR, 2003), que são $M = 200$ e $L = 0.267$.

O valor médio de n é fixo e vale 110, mas os valores de q e m dependem do tipo de MVN utilizado. A Tabela 6.24 exhibe os valores médios de q , m e de *PFM* para cada tipo de MVN.

Tipo de MVN	q	m	PFM
MVN01	84	125	$1,39 \times 10^{-49}$
MVN02	85	126	$1,33 \times 10^{-50}$
MVN03	84	124	$4,86 \times 10^{-50}$
MVN04	87	141	$3,56 \times 10^{-47}$

Tabela 6.24 – Para cada tipo de MVN testado, são apresentados os valores de q (média de minúcias coincidentes), m (média de minúcias geradas) e PFM (probabilidade de ocorrer uma falsa correspondência entre dois conjuntos de minúcias).

Da Tabela acima, pode-se observar que a menor PFM obtida está associada ao MVN02, que utiliza a rede MLP treinada com a base B_MBCA.

As figuras 6.17, 6.18 e 6.19 exibem respectivamente, as minúcias extraídas das imagens U295, U238 e G099 extraídas utilizando-se o MVN02.



Figura 6.17 – Minúcias extraídas da Imagem U295 (boa qualidade) utilizando-se o MVN02, que possui a menor PFM . A imagem possui 107 minúcias genuínas, mas o extrator encontrou 94 (87,85%) e gerou 19 (17,76%) minúcias falsas.

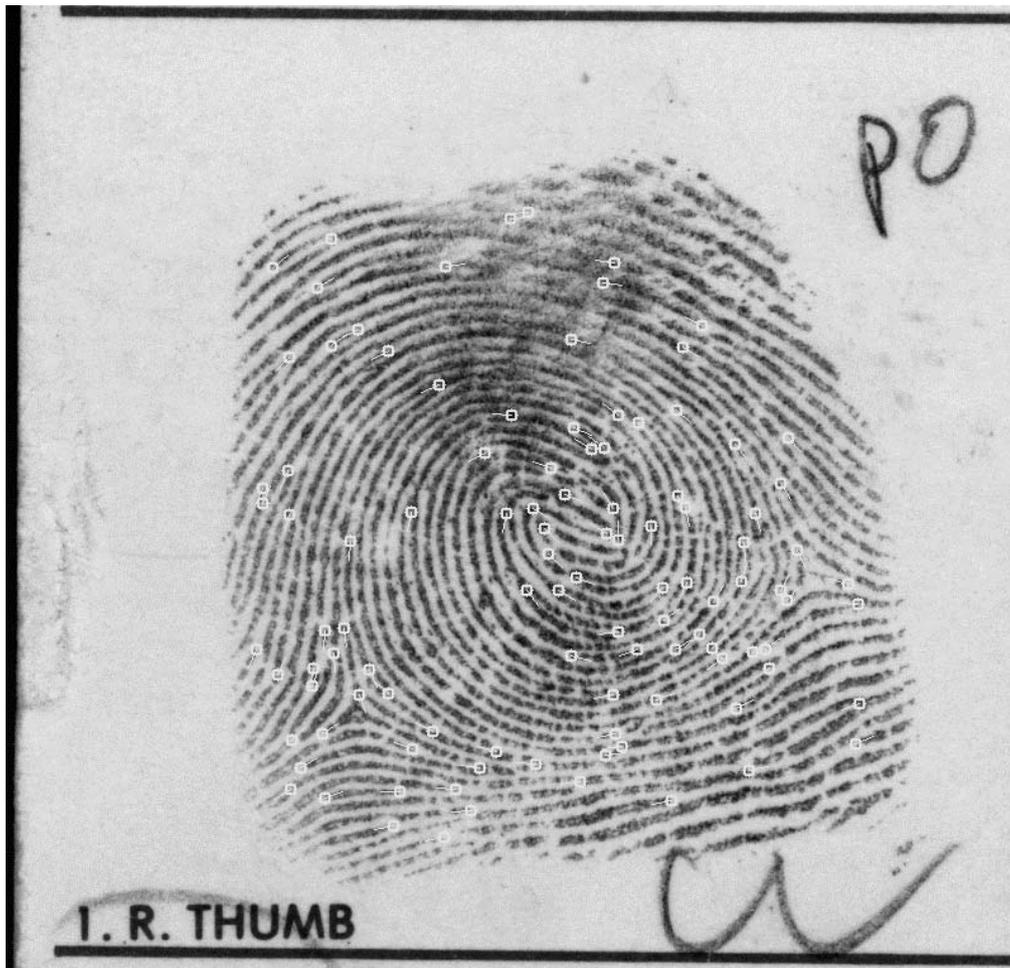


Figura 6.18 – Minúcias extraídas da Imagem U238 (má qualidade) utilizando-se o MVN02, que possui a menor *PFM*. A imagem possui 97 minúcias genuínas, mas o extrator encontrou 76 (78,35%) e gerou 30 (30,93%) minúcias falsas.

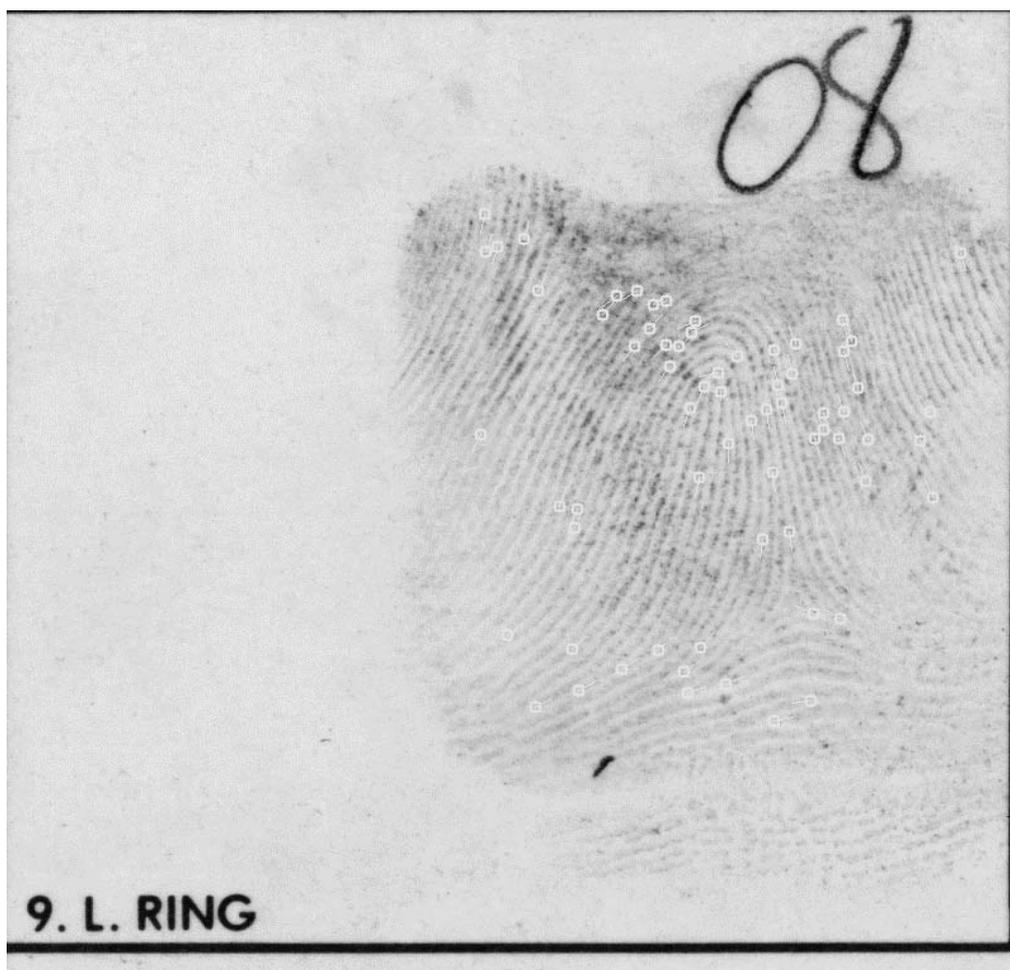


Figura 6.19 – Minúcias extraídas da Imagem G099 (péssima qualidade) utilizando-se o MVN02, que possui a menor *PFM*. A imagem possui 55 minúcias genuínas, mas o extrator encontrou 26 (47,27%) e gerou 41 (74,55%) minúcias falsas.

Em um AFIS, a taxa de FMR (*False Match Rate*) poderia ser estimada pela equação 6.7.

$$FMR = N \times PFM \quad (\text{eq. 6.7})$$

Onde *N* é o número de padrões presente na base AFIS.

6.4 Conclusões

Dos resultados apresentados na seção anterior, verificou-se que a taxa de minúcias genuínas detectadas pelo extrator está em torno de 75%, e a quantidade de

minúcias espúrias geradas está na faixa de 38%. Apesar dos resultados não serem excelentes, os seguintes pontos devem ser levados em consideração:

- 1) A base de dados utilizada é a base extraída de (GARRIS, MCCABE, 2000), que possui imagens utilizadas em fichas de identificação, onde a qualidade da imagem não é alta, pois não havia uma preocupação com sistemas totalmente automáticos, já que o AFIS americano é semi-automático;
- 2) A quantidade de minúcias médias corretamente encontradas pelo extrator está em torno de 80 minúcias. Dependendo do sistema, doze minúcias identificadas corretamente são mais que suficiente para identificar uma digital, em um tribunal, por exemplo, este número é muito aceito como evidência suficiente para identificação (do criminoso ou da vítima) (MALTONI, MAIO, JAIN, PRABHAKAR, 2003);
- 3) A quantidade de minúcias falsas geradas por um extrator é um ponto preocupante, pois quanto maior o conjunto de minúcias, maior é a probabilidade de ocorrer uma falsa correspondência, ou seja, pode ocorrer que as falsas minúcias geradas juntamente com as minúcias genuínas de uma impressão digital sejam confundidas com o conjunto de minúcias falsas e genuínas de outra impressão digital. Porém, como visto, a quantidade de minúcias falsas geradas está em torno de 30 e utilizando-se o modelo proposto em (MALTONI, MAIO, JAIN, PRABHAKAR, 2003), a probabilidade de uma falsa correspondência utilizando-se o melhor MVN foi de $1,74 \times 10^{-53}$. Em uma base AFIS com 200 milhões (2×10^8) de impressões digitais a taxa *FMR* pode ser estimada como, $FMR = 2 \times 10^8 \times 1,33 \times 10^{-50} = 2,66 \times 10^{-42}$.

Desta forma, pode-se concluir que o extrator de minúcia proposto neste trabalho pode ser utilizado em um sistema automático de impressões digitais onde a qualidade da imagem pode ser melhorada utilizando-se *livescanners*, como por exemplo, em uma aplicação de controle de acesso, já que a performance do extrator com imagens de boa qualidade é alta. O extrator também pode ser utilizado em sistemas semi-automático, já que mais de 70 % das minúcias estão corretamente marcadas, isso diminuiria o trabalho do perito em impressões digitais.

Apenas para fins de comparação, o método tradicional de extração de minúcias foi implementado sofrendo algumas alterações. Antes de se aplicar a binarização, a imagem é filtrada com o filtro de Gabor para realçar a qualidade da imagem.

Uma minúcia extraída pelo método tradicional é considerada genuína se a distância dela para uma minúcia real for menor ou igual a 10 pixels. Observe que a restrição para o método tradicional é menos rigorosa, pois para o método de extração proposto, uma minúcia é genuína se ela possuir distância menor que 10 pixels e o cosseno do ângulo de diferença maior ou igual a 0.9 (equação 6.5). A Tabela 6.25 exhibe os valores de pmv e pmf obtidos pelo modelo de extração tradicional testado nas mesmas 12 imagens de teste, e exhibe também estes valores para o extrator que utiliza o MVN02.

Método de	pmv	pmf
TRADICIONAL	69.43%	42.4%
MVN02	75,55%	38,41%

Tabela 6.25 – Valores percentuais de minúcias corretamente encontradas (pmv) e de minúcias falsas geradas (pmf), para o modelo tradicional e para o modelo proposto utilizando o MVN02.

Da tabela anterior pode-se verificar que com relação ao método tradicional houve um ganho de $75,55\% - 69,43 = 6,12\%$ na detecção correta de minúcias, e uma redução de $42,4 - 38,41 = 3,99\%$ na taxa de falsas minúcias geradas.

7 CONCLUSÕES

A biometria é o estudo de características físicas e comportamentais que podem ser utilizadas para fins de identificação ou certificação de pessoas. Sendo as impressões digitais uma das características biométricas mais conhecidas.

As impressões digitais sempre foram muito utilizadas para solução de crimes, na identificação de criminosos e vítimas. Porém, com o advento dos computadores surgiram novas aplicações para as impressões digitais, como por exemplo, transações que necessitam da certificação da identidade da pessoa, ou seja, é necessário saber se uma pessoa é quem ela diz ser.

A biometria não se limita somente ao estudo de impressões digitais, mas, como já dito, ao estudo de qualquer característica física ou comportamental. A seguir, são apresentadas algumas características biométricas que atualmente utilizadas e estudadas:

- **DNA:** a informação genética, presente no núcleo de todas as células de qualquer ser vivo, é única por indivíduo salvo irmãos gêmeos univitelinos. A comparação de duas seqüências de DNA pode ser feito através de comparação aproximada de cadeias (NAVARRO, 2001);
- **VOZ:** a voz humana é composta por fatores fisiológicos e comportamentais que não variam, ou variam muito pouco, com o tempo. A voz não possui um grau de distinção muito alto. Estudos sobre a voz podem ser encontrados em (MAES, NAVRÁTIL, CHAUDAHARI, 2001; DINIZ, 1997);
- **FACE:** o desenho do rosto de alguém é único, e é uma das características mais utilizadas por pessoas para se identificarem. Modelos de sistemas de reconhecimento por face são propostos em (DASS, JAIN, LU, 2002; ROWLEY, BALUJA, KANADE, 1998);
- **ÍRIS:** a íris é uma das características mais famosas, pois possui um grau de precisão maior do que as impressões digitais, ou seja, é mais provável que haja duas impressões digitais iguais do que duas íris iguais. O reconhecimento por íris é feito localizando-se pontos singulares nela presentes. Este conjunto de pontos é único por íris. Estudo e modelos de reconhecimento por íris podem ser encontrados em (KRONFELD, 1962; DAUGMAN, 2004).

Existem outras características biométricas utilizadas e estudadas, porém, as mencionadas anteriormente são as principais. Esta dissertação teve como foco de estudo as impressões digitais.

Uma impressão digital é formada por linhas e sulcos presentes na pele das áreas de contato, como palma das mãos, ponta dos dedos e planta dos pés. As linhas de uma impressão digital possuem pontos, conhecidos como minúcias, que consistem das posições aonde uma linha termina ou bifurca. O conjunto de minúcias de uma impressão digital é único. Portanto, o reconhecimento através de impressões digitais é geralmente feito localizando-se as minúcias.

Um sistema de extração automática de minúcias consiste basicamente das seguintes fases:

- **Pré-processamento:** nesta fase são aplicados filtros sobre a imagem, com o objetivo de realçar a sua qualidade ou alguma característica. Filtros utilizados em impressões digitais podem ser encontrados em (GONZALEZ, WOODS, 2000; HONG, WAN, JAIN, 1998; LEUNG, ENGELER, FRANK, 1990);
- **Segmentação ou Detecção da Região de Interesse:** esta fase é responsável pela detecção da região da imagem que possui a impressão digital separando-a das demais regiões da imagem. Métodos para segmentação são propostos em (JAIN, 1989; RATHA *et. al*, 1996; CHEN, TIAN, CHENG, YANG, 2004);
- **Extração de Características:** nesta fase ocorre a extração das minúcias. Para esta fase, vários pesquisadores propuseram diferentes abordagens, como podem ser encontrados em (JAIN, PANKANTI, 1997; LEUNG, LEUNG, LAU, LUK, 1991; NETO, 2000; MALTONI, MAIO, 1997; JIANG, YAU, SER 2001; LIU HUANG, CHAN, 2000; LEUNG, ENGELER, FRANK, 1990; SAGAR, NGO, FOO, 1995; SAGAR BENG, 1999);
- **Pós-processamento:** esta fase tem como objetivo refinar o resultado obtido da fase anterior, removendo eventuais características espúrias. Exemplo de abordagens para execução desta fase podem ser encontrados em (JAIN, PANKANTI, 1997; MALTONI, MAIO, 1998; MALTONI, MAIO, JAIN, PRABHAKAR, 2003; NETO, 2000).

Nesta dissertação foram propostos métodos para as 3 primeiras fases:

- na fase de pré-processamento é proposta uma modificação no método de equalização local. Nesta fase também é proposto o uso de uma rede neural para aproximar o filtro de Gabor e reduzir o custo computacional da operação de filtragem;
- na fase de segmentação é proposto um modelo baseado em redes neurais para a detecção das regiões da imagem que possuem impressões digitais;
- para a fase de extração de minúcias é proposto um método que utiliza o filtro de Gabor Neural, proposto para a fase de pré-processamento, para a detecção de regiões candidatas a minúcias e a utilização de um módulo neural para a validação das minúcias extraídas.

As seções seguintes apresentam, de forma simplificada, cada uma das propostas e as suas respectivas conclusões.

7.1 Pré-processamento

Para fase de pré-processamento, foram utilizados basicamente 2 filtros, o filtro de equalização de histograma (GONZALEZ; WOODS, 2000) e o filtro de Gabor (HONG, WAN, JAIN, 1998; LEUNG, ENGELER, FRANK, 1990).

A equalização de histograma é um algoritmo já conhecido na área de processamento de imagens e possui, como objetivo, tornar o histograma da imagem o mais uniforme possível. Porém, é observado que a aplicação deste filtro em uma imagem não traz muitos benefícios quando aplicado globalmente.

O resultado pode ser melhorado se a imagem for subdividida em imagens menores e o filtro aplicado individualmente, o que é chamado de equalização local. No entanto, a equalização local, aplicada desta forma, cria discontinuidades nas bordas entre as subimagens, criando um efeito de quadriculado. Para superar esta característica indesejável, foi proposto o uso de uma interpolação, que determina o tom de cinza de um pixel através da combinação dos tons cinza das subimagens vizinhas.

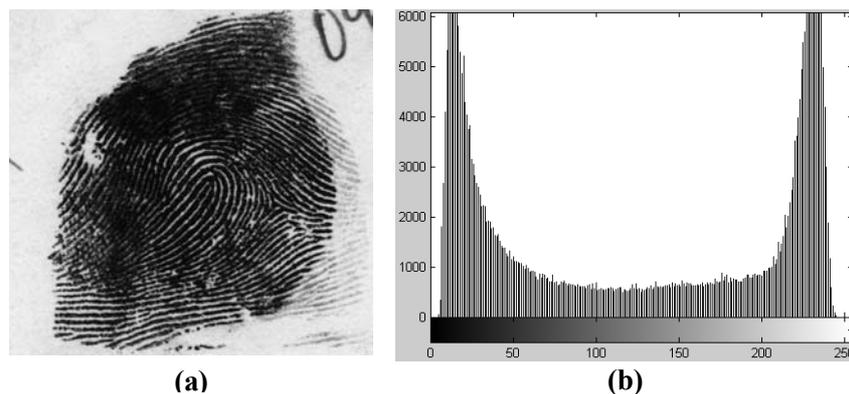


Figura 7.1 – (a) Imagem de uma impressão digital; (b) Histograma de (a).

A Figura 7.2 exibe a imagem resultante da equalização local interpolada da imagem 7.1(a) e seu histograma.

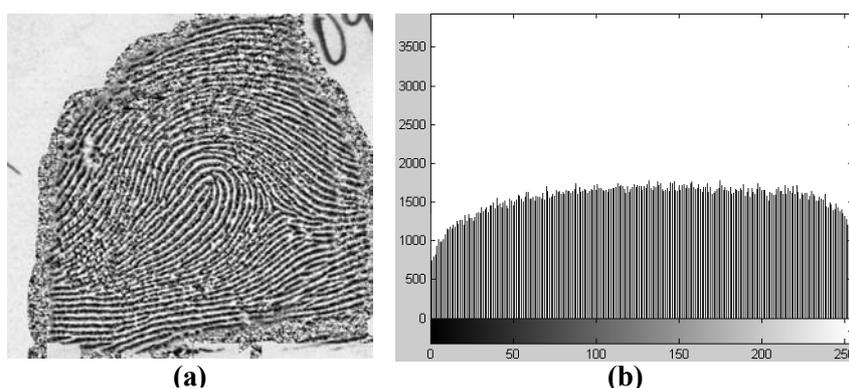


Figura 7.2 – (a) Imagem da impressão digital da Figura 7.1(a) após a equalização local interpolada; (b) Histograma de (a).

Dos resultados apresentados no Capítulo 4, pôde-se concluir que, como a equalização local proposta elimina o efeito de quadriculado e gera uma imagem com histograma com distribuição bem próxima da uniforme, o seu uso realmente traz uma melhoria à qualidade da imagem. A Figura 7.1 exibe uma imagem de impressão digital e seu respectivo histograma.

Outro filtro, muito utilizado em processamento de imagens de impressões digitais, é o filtro de Gabor, que pode ser tanto utilizado para realçar a qualidade da imagem quanto para detectar regiões candidatas conterem minúcias. O problema do filtro de Gabor é o seu elevado custo computacional. Com o objetivo de diminuir este custo, é proposta a utilização de uma rede neural com poucos neurônios para aproximar

a saída do filtro. Dos resultados apresentados no Capítulo 4 Seção 4.4.4, pôde-se observar que a rede, além de produzir um resultado muito semelhante ao filtro original, apresenta uma redução no número de operações de ponto flutuante utilizadas, executando cerca de 3,75 vezes menos operações de multiplicações e 1,54 vezes menos operações de soma. Portanto, pode-se concluir que o uso da rede neural para substituir o filtro de Gabor tradicional é compensado pelo fato da rede manter a qualidade do filtro e trazer uma redução no número de operações utilizadas.

7.2 Segmentação

A fase de segmentação ou detecção da região de interesse consiste em determinar qual região da imagem possui impressão digital. No Capítulo 5 um método de segmentação neural é proposto. A abordagem proposta se baseia na semelhança que há entre fragmentos de impressões digitais e funções senoidais bidimensionais, e no fato de que tais funções possuem um espectro de Fourier bem definido.

Uma rede neural foi treinada para identificar o padrão dos Espectros de Fourier das regiões que possuem impressão digital diferenciando-as das demais regiões da imagem. Dos resultados obtidos, verificou-se que o método consegue identificar, com uma taxa de acerto de cerca de 86%, as áreas da imagem pertencentes à impressão digital, gerando assim resultados satisfatórios. A Figura 7.3 exibe imagem de uma impressão digital e o resultado da segmentação.

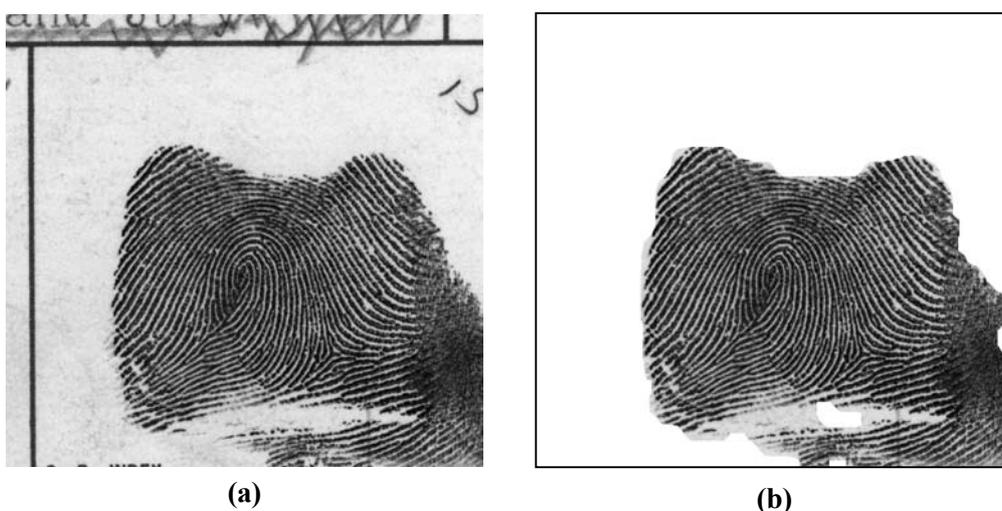


Figura 7.3 – (a) Imagem de uma impressão digital; (b) Imagem resultante do método de segmentação proposto no Capítulo 5.

7.3 Extração Automática de Minúcias

No Capítulo 6 é feita a proposta de um método neural para extração automática de minúcias a partir de uma imagem de impressão digital. O método proposto é composto de dois módulos, descritos a seguir:

- GNC: este módulo utiliza o filtro de Gabor Complexo para detectar regiões candidatas a possuírem minúcias. Como o filtro de Gabor complexo possui um grande custo computacional associado, foi utilizada a sua aproximação, proposta no Capítulo 4;
- MVN: este módulo utiliza um sistema neural que verifica as regiões geradas pelo GNC e determina a existência ou não de fins-de-linha ou bifurcações;

O módulo MVN foi testado com redes do tipo MLP (MultiLayer Perceptron) e FAM (Fuzzy-ARTMAP), que receberam como entrada fragmentos da imagem que tenham sido indicados, pelo GNC, como regiões candidatas a possuírem minúcias.

A Figura 7.4 exhibe exemplos de imagens de fim-de-linha, bifurcação e não-minúcia, que foram utilizados para o treinamento das redes testadas no módulo MVN.

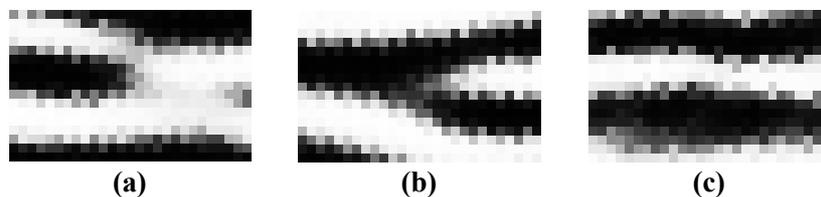


Figura 7.4 – (a) Imagem de um fim-de-linha; (b) Imagem de uma bifurcação; (c) Imagem de uma região que não é minúcia.

A Figura 7.5 exhibe uma imagem com as suas minúcias marcadas através do método proposto.

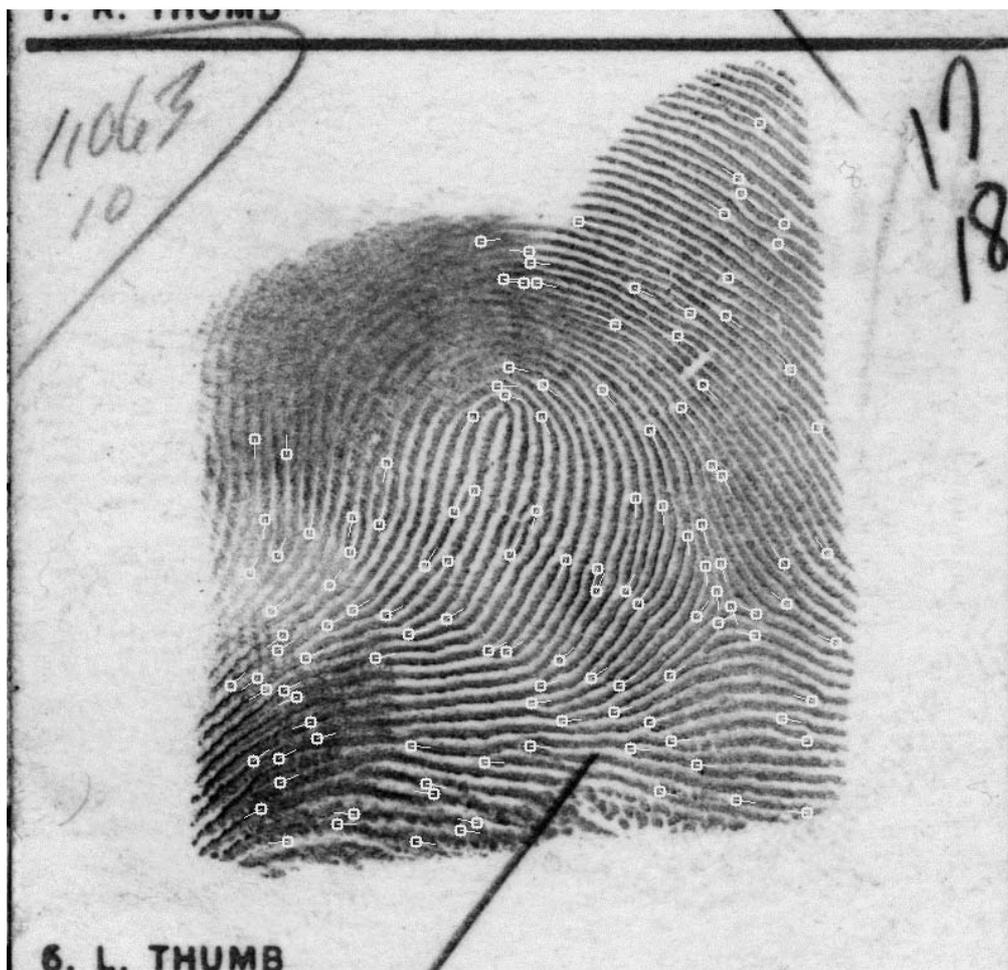


Figura 7.5 – Imagem de uma impressão digital com suas minúcias detectadas pelo método proposto no Capítulo 6.

Dos resultados obtidos pôde-se concluir que:

- o método proposto resultou em um ganho no número de minúcias corretamente detectadas e uma redução nas minúcias falsas geradas;
- utilizando-se a fórmula descrita em (MALTONI, MAIO, JAIN, PRABHAKAR, 2003) e as médias de acerto e erro do modelo proposto, pôde-se determinar que a probabilidade de ocorrer uma falsa correspondência, ou seja, afirmar que duas impressões digitais diferentes são iguais, é de $1,74 \times 10^{-53}$.

7.4 Trabalhos futuros

Como trabalhos futuros que possam ser feitos em decorrência do estudo aqui apresentado, devem ser citados tanto trabalhos que possam melhorar o desempenho do método de extração de minúcias quanto estudos que possam explorar outras características das impressões digitais. A seguir são listadas algumas sugestões:

- o filtro de Gabor pode resultar em melhoria significativa na qualidade da imagem, porém, ele pode, por exemplo, conectar linhas da impressão digital que na realidade não estão conectadas, gerando assim uma falsa bifurcação. Uma alternativa futura seria o estudo de filtros que possam melhorar a qualidade da imagem gerando menos falsas minúcias;
- utilizar outros modelos de classificação, por exemplo, em (DOLLFUS, BEAUFORT, 1999) é proposta uma arquitetura de rede neural, voltada para reconhecimento de estruturas naturais, que utiliza uma quantidade excessiva de neurônios visando a eliminação da fase de pré-processamento e extração de características. Ou seja, o vetor de entrada da rede é composto diretamente pelos pontos da imagem sem a aplicação de filtros;
- extrair outras características da impressão digital além das minúcias, como por exemplo, informações sobre a geometria das linhas que compõem a impressão digital. Este tipo de informação é particularmente importante quando se deseja fazer comparações que envolvem impressões digitais latentes, que geralmente consistem em um fragmento de baixa qualidade em que há pouca informação de minúcias, porém pode conter grande informação nas suas linhas.

8 REFERÊNCIAS BIBLIOGRÁFICAS

BABLER, WILLIAM J., **Embryologic Development of Epidermal Ridges and Their Configuration**, Birth Defects Original Article Series, Vol. 27, No 2, 1991.

BOLLE, RUUD M.; SENIOR, ANDREW W.; RATHA, NALINI K.; PANKANTI, SHARATH, **Fingerprint Minutiae: A Constructive Definition**, Proc. Workshop on Biometric Authentication, LNCS 2359, pp. 58-66, Springer Verlag, New York, 2002.

CARPENTER, G.A.; GROSSBERG, S.; MARKUZON, Natalya; REYNOLDS, John H.; ROSEN, David B.. **Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps**. IEEE Transactions on Neural Networks, Vol. 3, No 5, pp. 698-713, 1992.

DASS, S. C.; JAIN, A. K.; LU, XIAOGUANG. **Face Detection and Synthesis Using Markov Random Field Models**, Proc. of 16th International Conference on Pattern Recognition, Quebec City, Vol. 4, pp. 201- 204, August 11-15 , 2002.

DAUGMAN, JOHN, **Complete Discrete 2-D Gabor Transforms by Neural Networks for Image Analysis and Compression**. IEEE Trans. on Acoustics, Speech, and Signal Processing, Vol. 36, No 7, pp. 1169-1179, 1988.

DAUGMAN, JOHN. **How Iris Recognition Works**. IEEE Trans. CSVT 14(1), pp. 21 - 30, 2004.

DINIZ, SUELAINÉ DOS SANTOS. **Uso de Técnicas Neurais para o Reconhecimento de Comando à Voz**, IME – Tese de Mestrado, Julho de 1997.

DOLLFUS, D.;BEAUFORT, L., **Fat neural network for recognition of position-normalised objects**, Neural Networks, vol. 12, pp. 553-560, 1999.

GALTON, F., **Finger Prints**, McMillan, London, 1892.

GARRIS, Michael D.; MCCABE, R. Michael, **Nist Special Database 27 – Fingerprint Minutiae From Latent and Matching Tenprint Images**, 2000. Disponível em <http://www.nist.gov/srd/PDF%20files/nistsd27.pdf>. Acesso em : setembro de 2003.

GONZALEZ, RAFAEL C.; WOODS, RICHARD E. **Processamento de Imagens Digitais**. 1. ed. Edgard Blücher Ltda, 2000.

HAYKIN, Simon. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

HENRY, E., **Classification and Uses of Finger Prints**, Routledge, London, 1900.

HOEL, PAUL G.; PORT, SIDNEY C.; STONE, CHARLES J. **Introdução à teoria da probabilidade**, 1 ed. Interciência, 1978.

HONG, LIN; WAN, YIFEI; JAIN, ANIL. **Fingerprint Enhancement: Algorithm and Performance Evaluation**, IEEE Transactions Pattern Anal. Machine Intell., vol. 20, no. 8, pp. 777-789, 1998.

JAIN, ANIL K.; ROSS, ARUN; PRABHAKAR, SALIL. **An Introduction to Biometric Recognition**. IEEE Transactions on Circuits and Systems for Video Technology, Special Issue on Image-and Video-Based Biometrics, Vol. 14, No 1, Janeiro de 2004.

JAIN, A. K.; CHEN, H.; MINUT, S. **Dental Biometrics: Human Identification Using Dental Radiographs**, Proc. of 4th Int'l Conf. on Audio- and Video-Based Biometric Person Authentication (AVBPA), pp. 429-437, Guildford, UK, June 9-11, 2003.

JAIN, ANIL K.; PANKANTI, SHARATH; ROSS, ARUN. **A Prototype Hand Geometry-based Verification System**, Proc. of 2nd International Conference on Audio- and Video-based Biometric Person Authentication (AVBPA), Washington D.C., pp.166-171, March 22-24, 1999.

JAIN, Anil K. **Fundamentals of Digital Image Processing**. 1. ed. Prentice Hall, 1989.

JAIN, ANIL K.; PANKANTI, Sharath. **Fingerprint Classification and Matching**. 1997. Disponível em <http://www.research.ibm.com/ecvg/pubs/sharat-handbook.pdf>
Acesso em : 21 de maio de 2003.

JIANG, X. D.; YAU, W. Y.; SER, W., **Detecting the Fingerprint Minutiae by Adaptive Tracing the Gray Level Ridge**, Pattern Recognition, Vol. 34, No. 5, pp. 999-1013, 2001.

JOHNSON, Richard A.; WICHERN, Dean W., **Applied Multivariate Statistical Analysis**, 3 ed. Prentice-Hall International, Inc., 642 p. il ISBN 0 13 041807 2, 1992.

KRONFELD, P. **Gross anatomy and embryology of the eye**. In: The Eye, H. Davson, Ed., Academic Press: London, 1962.

LEUNG, M.T.; ENGELER, W.E.; FRANK, P. **Fingerprint Image Processing Using Neural Network**, proc. 10th conf. on Computer and Communication Systems, pp. 582-586, Hong Kong, 1990.

LEUNG, W. F.; LEUNG, S. H.; LAU, W. H.; LUK, ANDREW, **Fingerprint Recognition Using Neural Network**, Proc. of the IEEE Workshop Neural Networks for Signal Processing, pp. 226-235, 1991.

LIU, J.; HUANG, Z.; CHAN, K., **Direct Minutiae Extraction from Gray-Level Fingerprint Image by Relationship Examination**, Proc. International Conference on Image Processing, Vol. 2, pp. 427-430, 2000.

MAES, STÉPHANE H.; NAVRÁTIL, JIRÍ; CHAUDHARI, UPENDRA. **Conversational Speech Biometrics**. J. Liu and Y. Ye (Eds.): E-Commerce Agents, LNAI 2033, pp. 166-179, 2001.

MALTONI, DAVIDE; MAIO, DARIO, **Direct Gray-Scale Minutiae Detection in Fingerprints**, IEEE tPAMI, Vol. 19, No. 1, 1997.

MALTONI, DAVIDE; MAIO, DARIO, **Neural Network Based Minutiae Filtering in Fingerprints**, Proc. 14th International Conference on Pattern Recognition (ICPR), Brisbane (Australia), pp.1654-1658, Agosto 1998.

MALTONI, DAVIDE; MAIO, DARIO; JAIN, ANIL K.; PRABHAKAR, SALIL, **Handbook of Fingerprint Recognition**, 1 ed. Springer – Verlag New York, Inc., 348 P. ISBN 0-387-95431-7, 2003.

MENDEL, GREGOR. **Experiments in Plant Hybridization**, Read at the meetings of February 8th, and March 8th, 1865.

MOUTINHO, Adriano M.; THOMÉ, Antônio Carlos Gay; BIONDI, Luiz B. Coelho; MEZA, Lúcia Ângulo, **Localização de Faces usando Redes Neurais Artificiais**, International Conference Enterprise Information Systems (ICEIS), 2004.

NAVARRO, GONZALO. **A Guided Tour to Approximate String Matching**. ACM Computing Surveys, Vol. 33, No. 1, March 2001.

NETO, AMERICO LOBO. **Extração automática de minúcias de impressões digitais**. Monografia (Bacharelado em Ciência da Computação), UFF – Universidade Federal Fluminense, 2000.

RATHA, N. *et al.* **A Real-time Matching System for Large Fingerprint Database**. IEEE Pattern Analysis and Machine Intelligence, vol. 18, no. 8, pp. 779-813, 1996.

ROWLEY, HENRY A.; BALUJA, SHUMEET; KANADE, TAKEO. **Neural Network-Based Face Detection**, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 20, pp. 23-38, Jan 1998.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J., **Learning representations by back-propagation errors**, Nature, pp. 323:533-536, 1986.

SAGAR, V. K.; NGO, D. B. L.; FOO, K. C. K., **Fuzzy Feature Selection for Fingerprint Identification**, Proc. of IEEE 29th Annual International Carnahan Conference on Security Technology, pp. 85-90, 1995.

SAGAR, V. K.; BENG, K. J., **Hybrid fuzzy logic and neural network model for fingerprint minutiae extraction**. International. Joint Conf. on Neural Networks, Vol. 5, pp. 3255-3259, 1999.