

UNIVERSIDADE ESTADUAL PAULISTA

“Júlio de Mesquita Filho”

Pós-Graduação em Ciência da Computação

Alex Fernando de Araujo

**Método para extração e caracterização de
lesões de pele usando difusão anisotrópica,
crescimento de regiões, *watersheds* e
contornos ativos**

UNESP

2010

Alex Fernando de Araujo

Método para extração e caracterização de lesões de pele usando difusão anisotrópica, crescimento de regiões, *watersheds* e contornos ativos

Orientador: Prof. Dr. Aledir Silveira Pereira

Dissertação de Mestrado elaborada junto ao Programa de Pós-Graduação em Ciência da Computação Área de Concentração em Sistemas de Computação/Processamento de Imagens e Visão Computacional, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Alex Fernando de Araujo

Método para extração e caracterização de lesões de pele usando difusão anisotrópica, crescimento de regiões, *watersheds* e contornos ativos

Dissertação apresentada para obtenção do título de Mestre em Ciência da Computação, área de Sistemas de Computação / Processamento de Imagem e Visão Computacional junto ao Programa de Pós-Graduação em Ciência da Computação do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Campus de São José do Rio Preto.

BANCA EXAMINADORA

Prof. Dr. Aledir Silveira Pereira
UNESP - São José do Rio Preto
Orientador

Prof. Dr. Norian Marranghello
UNESP - São José do Rio Preto

Prof. Dr. Ivan Nunes da Silva
USP - São Carlos

São José do Rio Preto, 01 de fevereiro de 2010

Agradecimentos

Primeiramente a Deus, por me dar forças e por permitir a conclusão deste projeto.

Ao Prof. Dr. Aledir Silveira Pereira, por me incentivar, orientar e mostrar os melhores caminhos a serem seguidos para o bom desenvolvimento deste trabalho.

Ao Doutor Ricardo Rossetti, especialista em doenças dermatológicas da clínica Derme de São José do Rio Preto, pela validação dos resultados obtidos pelo método desenvolvido.

À toda a minha família, pelo apoio e incentivo.

À Nathasa, pelo incentivo, pela ajuda com a correção do trabalho e por estar do meu lado durante todo o desenvolvimento do mesmo.

Aos professores Dr. João Manuel R. S. Tavares, Dr. C. A. M. Barbosa e Esp. Acrísio José do Nascimento Jr., pelo incentivo.

Aos amigos do LACE pelo apoio e amizade durante o período em que estivemos juntos.

Aos demais amigos pelo apoio e compreensão durante o período do mestrado.

À CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e da FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo), pelo suporte financeiro para o desenvolvimento deste trabalho.

Sumário

Lista de Figuras	p. vii
Lista de Tabelas	p. xi
1 Introdução	p. 1
Contribuições do trabalho	p. 2
Organização do trabalho	p. 3
2 Fundamentação teórica	p. 4
2.1 Introdução sobre o diagnóstico de lesões de pele	p. 4
2.2 Conceitos básicos de processamento de imagens digitais	p. 6
2.2.1 Passos fundamentais em processamento de imagens	p. 7
2.2.2 Relacionamentos entre pixels	p. 8
Vizinhança	p. 8
Conectividade	p. 9
Distâncias métricas	p. 10
2.2.3 Morfologia matemática	p. 11
2.2.4 Filtros	p. 11
Filtros lineares	p. 12
Filtros não-lineares	p. 16
2.2.5 Representação de fronteiras por assinatura	p. 22
2.2.6 Crescimento de Regiões	p. 23
Crescimento por fusão (<i>Quadtree</i>)	p. 24

Crescimento por <i>watershed</i>	p. 24
Método de crescimento de regiões de Mumford-Shah	p. 27
<i>Merge</i> (União)	p. 30
2.2.7 Quantização de cores	p. 30
2.2.8 Segmentação de imagens	p. 31
2.3 Contornos ativos (<i>Snakes</i>)	p. 32
2.3.1 Representação de contorno ativo	p. 32
Energia interna (E_{int})	p. 33
Energia externa (E_{ext})	p. 34
Minimização da energia no modelo tradicional	p. 34
Discretização do modelo tradicional por diferenças finitas	p. 35
Limitações do modelo tradicional	p. 36
Contorno ativo baseado no fluxo do vetor gradiente	p. 37
2.4 Suavização de imagens usando difusão anisotrópica	p. 39
3 Método desenvolvido	p. 44
3.1 Suavização	p. 45
3.1.1 Estimativa automática do número de iterações da difusão anisotrópica	p. 46
3.1.2 Aplicação da difusão anisotrópica	p. 49
3.2 Crescimento de regiões	p. 50
3.3 <i>Merge</i> (União)	p. 56
3.4 Definição do contorno inicial da lesão	p. 61
3.5 Pós-processamento do contorno inicial	p. 62
3.5.1 Aplicação do método de <i>watershed</i>	p. 62
3.5.2 Aplicação do modelo de contorno ativo	p. 63
3.6 Caracterização das bordas	p. 67

3.6.1	Cálculo do diâmetro (D)	p. 68
3.6.2	Definição da assimetria (A)	p. 69
3.6.3	Cálculo da quantidade de ispículos (B)	p. 71
3.6.4	Cálculo da variação de cores (C)	p. 75
4	Resultados e discussão	p. 77
4.1	Comparação de três métodos de extração de características de lesões de pele	p. 77
4.2	Comparação do método desenvolvido em relação ao método utilizado comercialmente	p. 89
	Conclusão	p. 93
	Trabalhos futuros	p. 95
	Referências	p. 96
	Apêndice	p. 100

Lista de Figuras

2.1	Passos fundamentais em processamento de imagens [22].	p. 7
2.2	Vizinhanças: (a) $N_4(p)$; (b) $N_D(p)$ e (c) $N_8(p)$	p. 9
2.3	Conectividades: (a) de 4; (b) de 8 e (c) mista.	p. 10
2.4	Distâncias (a) Euclidiana, (b) <i>City-Block</i> e (c) <i>Chessboard</i> com $D \leq 2$ do pixel central.	p. 10
2.5	Exemplo de máscara 3x3 sobre uma imagem.	p. 12
2.6	Exemplo da aplicação do filtro passa-baixa com média simples em um ponto.	p. 13
2.7	Exemplo da aplicação do filtro passa-baixa. Em (a) a imagem com ruído e em (b) o resultado do filtro.	p. 13
2.8	Máscara 3x3 de média ponderada.	p. 14
2.9	Exemplo de filtro passa-alta com a máscara (c).	p. 14
2.10	Exemplo de filtro passa-alta 3x3. Em (a) a imagem original e (b) a imagem resultante da aplicação do filtro.	p. 15
2.11	Máscaras regionais para os filtros de realce direcionais.	p. 15
2.12	Aplicação de filtros de realce. Em (a) a cena original; (b) e (c), os filtros direcionais leste e oeste, respectivamente.	p. 16
2.13	Máscaras do operador de Roberts (adaptado de [22]).	p. 17
2.14	Efeito da aplicação do operador de Roberts.	p. 17
2.15	Máscaras do operador de Sobel (adaptado de [22]).	p. 17
2.16	Efeito da aplicação do operador de Sobel.	p. 18
2.17	Máscaras de convolução usadas com o operador de Prewitt (adaptado de [22]).	p. 18

2.18	Efeito da aplicação do operador de Prewitt.	p. 18
2.19	Efeito da aplicação do operador de Canny.	p. 20
2.20	Representação do cálculo do filtro morfológico da mediana.	p. 21
2.21	Efeito do filtro morfológico da mediana.	p. 21
2.22	Efeito da dilatação (c) e da erosão (d), aplicados sobre a imagem (a). .	p. 22
2.23	Exemplo de assinatura de um quadrado de lado A (adaptado de [22]). .	p. 23
2.24	Efeito do método de crescimento de regiões.	p. 24
2.25	Esquema do método Quadtree [22].	p. 24
2.26	Imagem super-segmentada [Adaptado de [38]].	p. 26
2.27	Resultado da aplicação do método de quantização de cores. Em (a) a imagem original com 55.664 cores e em (b) a imagem quantizada com 155 cores.	p. 31
2.28	Relação entre pré-processamento, segmentação e pós-processamento. . .	p. 32
3.1	Diagrama de fluxo geral do método proposto.	p. 45
3.2	Diagrama de fluxo da etapa de suavização.	p. 46
3.3	Aplicação dos operadores de Prewitt em (b) e de Roberts (c) numa ima- gem ruidosa (a).	p. 47
3.4	Gráfico da evolução do número de pontos retornados pela aplicação dos operadores de Roberts e de Prewitt nas imagens apresentadas em baixo (a-d) com diferentes quantidades de ruído.	p. 48
3.5	Gráfico da evolução das iterações calculadas pelo método proposto nas imagens da figura 3.4.	p. 49
3.6	Resultado da aplicação de crescimento de região ((b) e (d)) em imagens sem suavizar ((a) e (c)).	p. 50
3.7	Resultado da aplicação de crescimento de região <i>quadtree</i> ((b) e (d)) nas imagens suavizadas (a) e (c).	p. 51
3.8	Imagem original (a) e suas componentes HSV, que são mostradas em (b) matiz, (c) saturação e (d) intensidade, respectivamente.	p. 52

3.9	Aplicação do crescimento de região na componente intensidade. (a) e (c) são as imagens originais suavizadas e (b) e (d) o resultado do crescimento de região.	p. 53
3.10	Aplicação do crescimento de região de Mumford-Shah na imagem RGB. (a) e (c) são as imagens originais suavizadas e (b) e (d) o resultado do crescimento de região.	p. 54
3.11	Diagrama de fluxo da etapa de crescimento de região.	p. 55
3.12	Resultado do crescimento de região na imagem RGB quantizada. (a) e (c) são as imagens suavizadas após a quantização e (b) e (d) o resultado do crescimento de região.	p. 56
3.13	Imagens após crescimento de região.	p. 57
3.14	(a) imagem após crescimento de regiões, (b) imagem binarizada com <i>merge</i> usando a média de intensidade dos cantos e (c) a imagem original.	p. 58
3.15	Imagem após aplicação do método de crescimento de regiões.	p. 58
3.16	Diagrama de fluxo da etapa de <i>merge</i>	p. 59
3.17	Imagens binarizadas pelo método <i>merge</i> usando a distância entre as cores das regiões como parâmetro de união.	p. 60
3.18	Contorno inicial sobreposto às lesões. O contorno encontra-se na cor branca.	p. 61
3.19	Em (a) tem-se a curva inicial usada pelo modelo de contorno ativo e em (b) os marcadores para o método <i>watershed</i>	p. 62
3.20	Aplicação do método de <i>watershed</i> adotado. Em (a) e (c) têm-se os contornos iniciais usados como marcadores e em (b) e (d) os resultados da aplicação do método.	p. 63
3.21	Exemplo dos modelos de contorno ativo tradicional (c) e GVF (d), aplicados sobre a curva (a). Em (b) tem-se a curva (a) sobreposta à imagem.	p. 65
3.22	Exemplo dos modelos de contorno ativo tradicional (b) e (d) e GVF (c) e (e) aplicados usando curvas iniciais diferentes. Em (a) tem-se a imagem original.	p. 66

3.23	Diagrama de fluxo da etapa de pós-processamento.	p. 67
3.24	Diagrama de fluxo da etapa de caracterização.	p. 68
3.25	Exemplos da maior diagonal (em vermelho), calculada pelo método de caracterização.	p. 69
3.26	Exemplo de comparação de uma linha perpendicular à diagonal maior, usada para definição da assimetria.	p. 70
3.27	Exemplo de histogramas das diferenças das perpendiculares de uma lesão simétrica (a) e assimétrica (b).	p. 71
3.28	Exemplo de um ponto de inflexão (vermelho) e seus vizinhos direitos (verde) e esquerdos (azul).	p. 72
3.29	Trecho da assinatura de uma borda, com as inflexões marcadas em azul e branco.	p. 73
3.30	Exemplos de produto vetorial.	p. 74
3.31	Exemplos dos picos e vales calculados usando o método desenvolvido a partir do produto vetorial.	p. 74
3.32	Exemplo do aumento na variação de cores (imagem (b)) causado pelo método de crescimento de regiões aplicado sobre a imagem (a).	p. 75
4.1	Erros provocados por serrilhamento excessivo resultante da aplicação do método de <i>watershed</i>	p. 84
4.2	Imagens 9 em (a) e 20 em (b), com suas respectivas diagonais maiores.	p. 87
4.3	Cálculo do diâmetro da lesão. Em (a) o diâmetro da lesão definido pelo especialista médico, e em (b) o diâmetro calculado a partir da borda retornada pelo método proposto neste trabalho.	p. 88
4.4	Imagem com borda da lesão detectada classificada como ruim.	p. 89
4.5	Comparação entre os resultados obtidos pelo <i>software SkinSeg</i> (linha 1) e o método desenvolvido neste trabalho (linha 2).	p. 90
4.6	Comparação entre os resultados obtidos pelo <i>software SkinSeg</i> (linhas 1 e 3) e o método desenvolvido neste trabalho (linhas 2 e 4).	p. 91

Lista de Tabelas

2.1	Guia ABCD das lesões de pele (Adaptado de [24]).	p. 5
3.1	Tabela de cores RGB das regiões 1, 2 e 3 da figura 3.15.	p. 58
3.2	Distâncias entre as cores das regiões 1, 2 e 3 da figura 3.15.	p. 59
3.3	Parâmetros usados nos modelos de contorno ativo.	p. 64
4.1	Resultados obtidos com o método desenvolvido neste trabalho.	p. 78
4.2	Exemplo do questionário apresentado ao dermatologista para validação dos resultados.	p. 83
4.3	Taxas de acerto dos métodos de pós-processamento propostos, usando um conjunto de 40 imagens como base de teste.	p. 84
4.4	Características extraídas das lesões.	p. 85
4.5	Avaliação da qualidade das melhores bordas, considerando um conjunto de 40 imagens como base de teste.	p. 88
4.6	Comparação da qualidade das bordas resultantes do método desenvolvido e do <i>SkinSeg</i>	p. 90

Abreviaturas

Max	<i>Máximo valor de um conjunto</i>
DNA	<i>DeoxyriboNucleic Acid</i>
ABCD	<i>Asymmetry Border irregularity Color change Diameter $\geq 6mm$</i>
div	<i>divergente</i>
conv	<i>convolução</i>
RGB	<i>Red (Vermelho) Green (Verde) Blue (Azul)</i>
HSV	<i>Hue (Matiz) Saturation (Saturação) Value (Intensidade)</i>
GVF	<i>Gradient Vector Flow</i>

Resumo

O diagnóstico médico auxiliado por computador tem se tornado cada vez mais frequente, como por exemplo, no diagnóstico de lesões de pele, para o qual técnicas para a extração automática dos contornos das mesmas torna-se crucial. Muitas vezes, algumas lesões passam despercebidas pelo dermatologista porque este pode estar com a visão cansada e ter dificuldade para identificar corretamente as características das regiões doentes. O método apresentado neste trabalho utiliza a difusão anisotrópica para fazer a suavização seletiva da imagem, preservando as bordas e permitindo a extração de contornos com suas principais características: forma e rugosidade. A aplicação do crescimento de regiões de Mumford-Shah possibilitou a extração de um contorno inicial, refinado pelos métodos de *watershed* e contorno ativo. As características das bordas detectadas foram extraídas de acordo com a regra ABCD, sendo os resultados validados por um especialista em doenças dermatológicas.

Palavras-Chaves: Segmentação de lesões de pele, crescimento de regiões, difusão anisotrópica, contorno ativo, *watershed*.

Abstract

The computer aided medical diagnosis has become increasingly common, such as the diagnosis of skin lesions, where the techniques for automatic extraction of their contours becomes crucial. Often, some lesions are overlooked by the dermatologist because his vision may be tired making it difficult for him to properly identify the characteristics of the injured regions. The method presented in this work uses anisotropic diffusion for a selective image smoothing, preserving the contour of the image, and allowing the extraction of the main characteristics of the identified contour: shape and roughness. The application of the Mumford-Shah method allows the extraction of an initial contour, which is then refined by the methods of watershed and active contour. The characteristics of the detected edges are extracted according to the ABCD rule, and the results are validated by an expert in dermatological diseases.

Keywords: skin lesions segmentation, region growth, anisotropic diffusion, active contour, watershed.

1 Introdução

As lesões de pele são frequentes e podem ser sinal de doenças graves para o ser humano, como por exemplo, o câncer de pele. O diagnóstico inicial destas lesões é feito a partir da análise de imagens obtidas através do exame de dermatoscopia (exame feito usando um instrumento óptico chamado dermatoscópio), ou de fotografias tiradas usando câmeras digitais. A partir da análise visual das regiões doentes, o dermatologista é capaz de dar um diagnóstico inicial sobre a classificação da lesão. No entanto, devido a fatores como cansaço do especialista médico e o tamanho das áreas doentes, o diagnóstico visual pode ser impreciso. Portanto, o desenvolvimento de técnicas computacionais que permitam uma análise inicial das lesões, a partir de imagens de pele, podem auxiliar no diagnóstico.

Os elementos das lesões que podem auxiliar no diagnóstico médico, são a rugosidade de suas bordas, a assimetria da lesão, o diâmetro e a variação de cor das áreas doentes. Desta forma, a detecção e extração de bordas da região doente é fundamental para o desenvolvimento de métodos computacionais, para auxiliar no diagnóstico de lesões de pele.

O objetivo deste trabalho é desenvolver um método para processamento e análise das imagens de pele, que seja capaz de detectar e caracterizar automaticamente as regiões com possíveis lesões. O primeiro passo neste processo é a detecção das bordas das lesões. A extração bem feita do contorno da região doente possibilita a correta caracterização e classificação da mesma [49].

O trabalho realizado utiliza a difusão anisotrópica para fazer a suavização seletiva da imagem, visando a redução de ruídos desta, preservando seus contornos. A manutenção das bordas é importante para permitir sua correta caracterização. Pois caso os contornos sejam danificados, suas irregularidades podem ser afetadas. O número de iterações aproximado para a difusão anisotrópica, é calculado através da diferença de pontos de bordas retornadas pelos operadores de Roberts e Prewitt, aplicados sobre a imagem original. Assim, a quantidade de iterações do método de suavização é calculada automaticamente

para cada imagem. A utilização de um modelo, fundamentado pela teoria de equações diferenciais parciais para a suavização, justifica-se pela forma de atuação diferenciada em pontos interiores e de borda dos objetos na imagem.

É importante destacar que as equações diferenciais parciais têm se tornado uma ferramenta importante e eficiente no tratamento de imagens digitais. Esta abordagem tem substituído com sucesso os filtros passa-baixa, em algumas aplicações, como em imagens de lesões de pele. Estas imagens, geralmente estão sujeitas à interferência de ruídos (bolhas, pêlos, dentre outros), e uma variação de brilho gerados devido à iluminação, à qual é submetida a lesão durante a captura das imagens.

Neste trabalho usam-se também técnicas de crescimento de regiões e *merge* para binarizar a imagem, separando as regiões saudáveis das possíveis lesões. O contorno obtido por estes métodos é pós-processado, com o objetivo de ajustá-lo melhor à lesão. Desta forma, as regiões doentes ainda não identificadas pelas etapas anteriores, são envolvidas pelo contorno. Uma análise de diversas técnicas de crescimento de regiões é feita, na tentativa de verificar qual o melhor método para a extração das bordas. O crescimento de regiões foi escolhido por proporcionar a análise de várias porções da cena separadamente, a partir da divisão desta em várias regiões menores. Além disso, para o pós-processamento, também foram analisadas abordagens de contornos ativos.

A caracterização das lesões é realizada a partir das bordas obtidas das imagens. Para definir a rugosidade, a assinatura das bordas foi extraída, analisando-se o tamanho e a quantidade de ispículos presentes na mesma. Os diâmetros e a assimetria das áreas doentes foram calculados a partir da distância entre os pixels do contorno, e a partir da localização do tecido doente obteve-se a variação de sua coloração.

Contribuições do trabalho

As contribuições efetivas deste trabalho foram:

- desenvolvimento de um critério para cálculo automático do número de iterações da suavização por difusão anisotrópica,
- eliminação da influência de reflexo e pêlos,
- aplicação de *watershed* e modelos de contorno ativo, a partir da borda obtida pelo crescimento de regiões de Mumford-Shah,

- desenvolvimento de um processo automático para avaliação de assimetria e,
- proposta para o cálculo do número de ispículos, baseado em inflexões das bordas.

Organização do trabalho

Este trabalho está organizado da seguinte forma: no capítulo seguinte é feita uma revisão sobre lesões de pele e processamento de imagens digitais. O capítulo 3 contém a descrição do método desenvolvido, apresentando cada etapa detalhadamente. Os testes realizados, os resultados obtidos, bem como a validação e a discussão destes, são mostrados no capítulo 4, seguido das conclusões do trabalho, e de propostas para trabalhos futuros.

2 Fundamentação teórica

Neste capítulo são apresentados os conceitos básicos aplicados no trabalho. Tais conceitos permitem o entendimento de algumas técnicas de processamento e análise de imagens digitais, utilizadas para detecção e extração de características de lesões de pele.

2.1 Introdução sobre o diagnóstico de lesões de pele

O alto índice de lesões de pele adquiridas de várias formas, e as consequências que elas trazem para o paciente, podendo vir a ser um câncer de pele, torna a sua detecção precoce de extrema importância para definição do tratamento mais adequado. As lesões de pele provocadas por células cancerosas podem levar até 20 anos para se manifestar. No entanto, após se manifestarem, algumas formas crescem lentamente enquanto outras (os melanomas, por exemplo) podem crescer e se espalhar rapidamente pelo corpo [24]. A demora na manifestação das lesões decorre do fato de que as cancerígenas geralmente se desenvolvem a partir de uma única célula doente, a qual sofreu alguma mutação desordenada, provocando danos no DNA.

Fatores como o tabaco e as exposições excessivas ao sol têm provocado um aumento acelerado dos casos de lesões de pele na população. No entanto, este aumento no número de casos de câncer de pele não é resultado apenas destes fatores. Algumas pesquisas demonstram que o aumento da expectativa de vida do ser humano, também foi um dos motivos para o aumento de ocorrências de câncer atualmente. É importante lembrar que até 1950 a expectativa de vida era muito inferior à atual, levando a maioria da população ao óbito antes da manifestação das lesões [7], [8]. Vale ressaltar também, que o diagnóstico precoce e bem realizado permite obter sucesso no tratamento e um aumento considerável nas chances de cura do indivíduo.

Para o diagnóstico das lesões de pele algumas características visuais como assimetria, irregularidade da borda, variação da cor interna e o diâmetro são observadas. Estas

características são conhecidas como ABCD das lesões de pele. Na tabela 2.1 apresenta-se este guia ABCD com mais detalhes.

Tabela 2.1: Guia ABCD das lesões de pele (Adaptado de [24]).

Característica	Descrição
Assimetria	<p>Simétrica: lesões que geralmente são não cancerosas e/ou não malignas, sendo mais arredondadas.</p> <p>Assimétrica: lesões que possuem grande probabilidade de serem cancerosas e malignas (melanomas).</p>
Borda	<p>Lisa: lesões não malignas possuem bordas lisas e suaves.</p> <p>Rugosa ou cortada: frequentemente lesões malignas possuem bordas irregulares.</p>
Cor	<p>Regular: lesões com cor interna homogênea que, na maioria das vezes, são não malignas.</p> <p>Irregular: geralmente os melanomas possuem coloração interna com grande variação das intensidades marrom e preta, podendo ter regiões isoladas em branco.</p>
Diâmetro	<p>< 6mm: lesões não malignas geralmente possuem diâmetro inferior a 6 milímetros e não variam de tamanho.</p> <p>≥ 6mm: frequentemente os melanomas são maiores do que 6mm de diâmetro, crescem e mudam de forma rapidamente.</p>

O fato dos melanomas crescerem e se modificarem rapidamente, tem levado a uma reavaliação do guia ABCD, onde pretende-se adicionar a característica “evolução” (*Evolving*), transformando o guia em ABCDE [25]. Uma pesquisa desenvolvida por Morris-Smith [34] revelou que os profissionais da área médica enfatizam muito estas características quando analisam as imagens de lesões, principalmente a irregularidade do contorno [11].

Este guia permite ao dermatologista fazer uma análise prévia da lesão, definindo os procedimentos a serem seguidos até que exames mais detalhados sejam feitos. Como exemplo, pode-se ter um paciente onde as características da lesão são de um melanoma. Neste caso, o médico pode optar pela extração total da lesão, mesmo antes de fazer a biópsia, o que aumentaria as chances de sobrevida deste paciente.

As imagens de lesões de pele são obtidas, de forma não invasiva, a partir de máquinas fotográficas ou, mais detalhadamente por meio de um exame de dermatoscopia. Neste segundo caso, um instrumento óptico chamado dermatoscópio é usado para fazer a captura

da imagem. Este equipamento possui lentes de aumento associadas a um sistema de iluminação, permitindo analisar as camadas mais profundas da pele. A principal vantagem de fazer a captura das imagens por dermatoscopia é o diagnóstico das lesões em seus estágios iniciais. No entanto, um fator negativo relacionado a este exame é que a maioria dos pequenos municípios não dispõem de tal tecnologia. Tal fato aumenta a importância de técnicas que permitam uma análise inicial das lesões a partir de imagens obtidas por máquinas fotográficas comuns.

A análise das imagens de pele são feitas pelo dermatologista. Através delas ele pode analisar visualmente a lesão, e suas características, a fim de ter uma idéia sobre a sua classificação. No entanto, esta análise não é tarefa fácil, devido a fatores como o cansaço visual do dermatologista, e a interferência causada por pêlos ou bolhas sobre a região doente. Uma forma de minimizar estes problemas é extrair o contorno destas regiões. Assim, a irregularidade das lesões fica mais evidente, evitando que a principal característica do guia ABCD seja distorcida em caso de cansaço visual.

Estas imagens podem ser armazenadas e visualizadas em computadores. Desta forma, torna-se possível fazer seu tratamento e sua análise computacional. Através de técnicas de processamento de imagens digitais pode-se reduzir a interferência de ruídos (pêlos, bolhas, problemas de iluminação, dentre outros), detectar e extrair os contornos das regiões doentes, tornando o diagnóstico visual mais fácil para o dermatologista. Na seção seguinte são apresentados os conceitos básicos de processamento de imagens digitais, necessários para a compreensão de como usar o processamento de imagens no auxílio ao diagnóstico de lesões de pele, bem como para compreensão do restante do trabalho.

2.2 Conceitos básicos de processamento de imagens digitais

O interesse por processamento de imagens digitais vem aumentando muito devido às suas duas principais áreas de atuação: a melhoria da informação visual, para melhorar a visualização e interpretação humana, e o processamento de cenas para extração de características e informações, que possibilitem a percepção automática através de uma máquina [22].

O conjunto de aplicações de processamento de imagens também tem ficado cada vez mais diversificado. Por volta de 1920 surgiu uma das primeiras aplicações. Nesta época, as imagens eram transmitidas da Europa para Nova York via cabos localizados no oceano Atlântico, processadas para melhorar sua interpretação e então publicá-las nos jornais.

Os computadores evoluíram e foi surgindo a necessidade de manipular imagens cada vez maiores que envolvem várias áreas de conhecimento. O interesse na área foi crescendo e transformou o processamento de imagens em uma grande fonte de pesquisa, ampliando sua aplicação para a medicina, geologia, agricultura, cartografia, meteorologia, física, astronomia, dentre outras. Nas subseções seguintes são apresentados os passos fundamentais do processamento e análise de imagens digitais, bem como a descrição das principais técnicas utilizadas neste trabalho.

2.2.1 Passos fundamentais em processamento de imagens

Ao processar uma imagem, o objetivo global é produzir um resultado a partir da aplicação de uma sequência de passos. Como pode-se observar na figura 2.1, o primeiro destes passos é a aquisição da imagem a partir da digitalização de um sinal emitido por um sensor. O sensor pode ser uma câmera de TV monocromática ou colorida, uma câmera de varredura por linha, um sensor infravermelho, entre outros.




Figura 2.1: Passos fundamentais em processamento de imagens [22].

O pré-processamento da imagem é o segundo passo do processamento de imagens digitais. Sua principal função é melhorar a imagem para aumentar as chances de sucesso dos processos seguintes. O próximo estágio é a segmentação que divide uma imagem de entrada em partes ou objetos constituintes. Apesar de ser uma das tarefas mais difíceis no processamento de imagens digitais, a segmentação automática é importante porque torna o método mais flexível, permitindo a aplicação bem sucedida deste procedimento em várias imagens.

A saída da segmentação é constituída por um conjunto de pixels representando fronteiras ou então regiões completas. A representação por fronteira é adequada quando o

interesse está nas características de forma das regiões, como diâmetro, excentricidade, perímetro e assinatura. Já a representação por região é usada quando se pretende trabalhar com as propriedades internas da região segmentada, como a textura ou a forma do esqueleto. Em algumas aplicações pode acontecer das duas representações coexistirem, como acontece em aplicações de reconhecimento de caracteres, que frequentemente requerem algoritmos baseados na forma da borda, esqueletos e outras propriedades internas.

Após a escolha da representação, um método para descrever os dados deve ser especificado de forma que as características de interesse sejam enfatizadas. Este método procura extrair características que resultem em alguma informação quantitativa de interesse, ou que sejam básicas para discriminação entre classes de objetos.

O último estágio envolve o reconhecimento e a interpretação das características extraídas. O primeiro atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor, e o segundo envolve a atribuição de significado a um conjunto de objetos reconhecidos.

2.2.2 Relacionamentos entre pixels

Alguns relacionamentos primitivos entre os pixels de uma imagem são importantes durante processo de segmentação e extração de bordas. Estes relacionamentos podem ser usados no refinamento de bordas, na remoção de possíveis ruídos do contorno e na busca por limites fechados.

Vizinhança

A vizinhança de pixels é baseada na propriedade de adjacência entre eles. Para um par de pixels de uma imagem ser adjacente, eles precisam compartilhar uma borda (adjacente por borda) ou um vértice (adjacente por vértice). Considerando um pixel p , tem-se a vizinhança de 4 ($N_4(p)$), se este é adjacente por borda a 4 outros pixels, sendo dois na vertical e dois na horizontal (figura 2.2- a). Neste caso, as coordenadas de seus vizinhos são: $(x+1, y)$, $(x-1, y)$, $(x, y+1)$ e $(x, y-1)$.




Figura 2.2: Vizinhanças: (a) $N_4(p)$; (b) $N_D(p)$ e (c) $N_8(p)$.

Na vizinhança diagonal ($N_D(p)$), os vizinhos de p são adjacentes a ele pelos vértices (figura 2.2 - b). Os pixels desta vizinhança possuem coordenadas: $(x+1, y+1)$, $(x+1, y-1)$, $(x-1, y+1)$ e $(x-1, y-1)$. A junção das vizinhanças $N_4(p)$ e $N_D(p)$ forma a vizinhança $N_8(p)$ (Figura 2.2 - c).

Conectividade

A conectividade entre pixels é muito usada para estabelecer a fronteira de objetos em uma imagem digital. Para que um par de pixels seja conectado eles devem ser adjacentes e seus níveis de cinza devem atender a um critério de similaridade utilizado para definir a conectividade [22].

Considerando V um conjunto de níveis de cinza usado para definição da conectividade e dois pixels quaisquer p e q , tem-se que os principais tipos de conectividade são:

- **conectividade de 4:** p e q são conectados de 4 se seus níveis de cinza pertencem a V e $q \in N_4(p)$ (figura 2.3 - a).
- **conectividade de 8:** p e q são conectados de 8 se seus níveis de cinza pertencem a V e se $q \in N_8(p)$ (figura 2.3 - b).
- **conectividade mista:** p e q possuem conexão mista (ou são conectados de m) se seus níveis de cinza pertencem a V e se:
 - i) $q \in N_4(p)$.
 - ii) $q \in N_8(p)$ e $N_4(p) \cap N_8(q) = \emptyset$.

A conectividade mista é obtida a partir de uma modificação da conectividade de 8, com o objetivo de eliminar a redundância de caminhos, como pode-se ver na figura 2.3 - c.




Figura 2.3: Conectividades: (a) de 4; (b) de 8 e (c) mista.

Distâncias métricas

Considerando três pixels $p(x_1, y_1)$, $q(x_2, y_2)$ e $t(x_3, y_3)$, D é uma função distância se satisfizer as seguintes condições:

- $D(p, q) = 0 \iff p = q$;
- $D(p, q) = D(q, p)$ e
- $D(p, q) + D(q, t) \geq D(p, t)$.

Os principais tipos de distâncias são a Euclidiana, *City-Block* e *Chessboard* (figura 2.4).

		2						2				2	2	2	2	2
	$\sqrt{2}$	1	$\sqrt{2}$				2	1	2			2	1	1	1	2
2	1	0	1	2		2	1	0	1	2		2	1	0	1	2
	$\sqrt{2}$	1	$\sqrt{2}$				2	1	2			2	1	1	1	2
		2						2				2	2	2	2	2
(a)					(b)					(c)						

Figura 2.4: Distâncias (a) Euclidiana, (b) *City-Block* e (c) *Chessboard* com $D \leq 2$ do pixel central.

Distância Euclidiana: é a distância geométrica de pontos, definida pela equação 2.1:

$$D_{e(p,q)} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (2.1)$$

Distância *City-Block*: baseada na vizinhança de 4, é calculada percorrendo os pixels na horizontal e na vertical, ou pela equação 2.2:

$$D_{4(p,q)} = |x_1 - x_2| + |y_1 - y_2| \quad (2.2)$$

Distância *Chessboard*: baseada na vizinhança de 8, é calculada percorrendo os pixels na horizontal, vertical e diagonal, ou pela equação 2.3:

$$D_{8(p,q)} = \text{Max}(|x_1 - x_2|, |y_1 - y_2|) \quad (2.3)$$

2.2.3 Morfologia matemática

Os métodos baseados em morfologia matemática são usados para extrair características para representação e descrição da forma dos objetos de uma imagem. Quando aplicada em processamento de imagens, o foco da morfologia matemática é a estrutura geométrica dos objetos que formam as imagens, sendo muito usada para realce, filtragem e segmentação. O termo morfologia, quando aplicado em imagens, se refere à forma e à estrutura de um objeto, bem como ao relacionamento entre as partes deste. Desta forma, a morfologia é um caminho para descrever ou analisar a forma de um objeto digital.

A idéia de aplicar a morfologia na análise de imagens é dividir os objetos da cena em conjuntos de pixels com uma forma [48], [17]. As técnicas de processamento de imagens, baseadas em morfologia, são desenvolvidas de acordo com as formas dos elementos da imagem. Para tal, uma máscara chamada elemento estruturante, é escolhida para ser aplicada na imagem. Este elemento estruturante interage com cada objeto da cena, modificando sua forma e seu tamanho, permitindo extrair as características desejadas. Portanto, este elemento estruturante deve ter sua forma e tamanho conhecidos, para tornar possível a avaliação de um conjunto de objetos desconhecidos.

2.2.4 Filtros

A filtragem de uma imagem é a sua transformação, pixel a pixel, considerando as intensidades das cores ou níveis de cinza de cada ponto e dos seus vizinhos. A quantidade de vizinhos considerada é definida por uma matriz, denominada máscara, que é aplicada sobre a cena. Na figura 2.5, por exemplo, tem-se uma máscara 3x3 (figura 2.5-(a)), aplicada sobre o ponto localizado na quarta linha e na quarta coluna da imagem de entrada (posição $(4, 4)$).

Considerando o centro de uma máscara M na posição (i, j) , onde i é a linha e j a coluna, a imagem filtrada é obtida pela passagem de M sobre a imagem, de forma que o ponto $M(i, j)$ percorra cada pixel $p(x, y)$ da cena, substituindo sua intensidade através de uma transformação T , realizada sobre todos os vizinhos de $p(x, y)$ que são sobrepostos

por M . A transformação T depende dos pesos w_i da máscara. Na figura 2.5, o ponto $p(4, 4)$ na cena tem sua intensidade alterada para w'_5 , que é o resultado da aplicação de T no instante em que $M(i, j)$ está sobre $p(4, 4)$.




Figura 2.5: Exemplo de máscara 3x3 sobre uma imagem.

Filtros lineares

Os filtros lineares suavizam e realçam detalhes da imagem, além de reduzir o efeito de ruídos, mantendo a média da imagem. Alguns dos filtros desta categoria são o passa-baixa, o passa-alta e os filtros de realce.

Passa-Baixa: suaviza a imagem filtrando as frequências que correspondem às transições abruptas entre os objetos da cena (altas frequências), reduzindo assim o ruído e borrando a imagem. Um esquema da aplicação de uma máscara da média 3x3 em uma região da cena é ilustrado na figura 2.6. A expressão para o cálculo do novo valor de $p(x, y)$ é dada por:

$$p(x, y) = \frac{p(x-1, y-1) + p(x-1, y) + p(x-1, y+1) + p(x, y-1) + p(x, y) + p(x, y+1) + p(x+1, y-1) + p(x+1, y) + p(x+1, y+1)}{9} \quad (2.4)$$

Pode-se observar que na saída mostrada na figura 2.6(b), o ponto filtrado teve seu nível de cinza substituído pela média de seus vizinhos. A aplicação desta mesma máscara em uma imagem provoca a suavização e eliminação de parte dos ruídos. Na figura 2.7 tem-se a imagem antes e depois da aplicação do filtro da média.




Figura 2.6: Exemplo da aplicação do filtro passa-baixa com média simples em um ponto.




Figura 2.7: Exemplo da aplicação do filtro passa-baixa. Em (a) a imagem com ruído e em (b) o resultado do filtro.

O filtro passa-baixa também pode ser implementado usando uma máscara de média ponderada. Neste caso, são definidos pesos para cada ponto. Para manter a característica dos filtros lineares, onde a soma de todos os valores da máscara tem que ser igual a 1, o ponto central na máscara usada como exemplo na figura 2.8 tem peso 2, enquanto os demais tem peso 1.

1/10	1/10	1/10
1/10	1/5	1/10
1/10	1/10	1/10

Figura 2.8: Máscara 3x3 de média ponderada.

Passa-alta: realça os detalhes da imagem, tornando mais nítida a transição entre as regiões distintas da cena. Estes filtros são usados frequentemente para destacar bordas, linhas curvas ou manchas. O ponto negativo deste filtro é que os ruídos também são reforçados. Um esquema de um filtro passa-alta em uma região da imagem é mostrado na figura 2.9.




Figura 2.9: Exemplo de filtro passa-alta com a máscara (c).

A expressão para o cálculo de $p(x, y)$, usando a máscara deste esquema é dada por:

$$p(x, y) = 4p(x, y) - p(x - 1, y) - p(x, y - 1) - p(x, y + 1) - p(x + 1, y). \quad (2.5)$$

O resultado do realce de bordas através do filtro passa-alta pode ser visto na figura 2.10. Nota-se que, além das transições abruptas de níveis de cinza que são realçadas, os ruídos da cena também são reforçados.




Figura 2.10: Exemplo de filtro passa-alta 3x3. Em (a) a imagem original e (b) a imagem resultante da aplicação do filtro.

Filtros de realce: realçam a imagem segundo as direções preferenciais definidas pelas máscaras. A máscara é nomeada de acordo com a direção que as fronteiras dos objetos são realçadas. As principais máscaras para a operação de realce, figura 2.11, são as máscaras norte e sul que realçam limites horizontais, as leste e oeste que reforçam os verticais e as nordeste, sudoeste, sudeste e noroeste que atuam nas diagonais.

Norte	Sul	Nordeste	Sudoeste
1 1 1	-1 -1 -1	1 1 1	1 -1 -1
1 -2 1	1 -2 1	-1 -2 1	1 -2 -1
-1 -1 -1	1 1 1	-1 -1 1	1 1 1
Leste	Oeste	Sudeste	Noroeste
-1 1 1	1 1 -1	-1 -1 1	1 1 1
-1 -2 1	1 -2 -1	-1 -2 1	1 -2 -1
-1 1 1	1 1 -1	1 1 1	1 -1 -1

Figura 2.11: Máscaras regionais para os filtros de realce direcionais.

Pode-se observar na figura 2.12, que nas imagens (b) e (c) as bordas verticais de (a) aparecem realçadas. Observando o olho do papagaio, percebe-se que em (b) as bordas do lado leste foram realçadas, ao passo que em (c) as do lado oeste foram reforçadas. Isto aconteceu porque estas imagens são resultantes da aplicação dos filtros leste e oeste,

respectivamente.




Figura 2.12: Aplicação de filtros de realce. Em (a) a cena original; (b) e (c), os filtros direcionais leste e oeste, respectivamente.

Filtros não-lineares

Os filtros não-lineares realçam e suavizam as bordas, reduzindo os ruídos de uma imagem e alterando sua média. Os principais filtros desta categoria são os operadores para detecção de bordas e os filtros morfológicos. A idéia de filtragem continua sendo a mesma, mas o filtro não-linear deve ser visto como uma função não-linear que opera sobre os pixels de uma região vizinha ao ponto central da máscara. Os operadores para detecção de bordas encontram linhas e curvas que limitam os componentes da cena. Os mais comuns são os operadores de Roberts, Sobel, Prewitt e Canny.

O operador de Roberts usa a máscara da figura 2.13(b) para fazer a aproximação das primeiras derivadas G_x e G_y . Considerando a vizinhança dada pela figura 2.13(a), obtém-se que $G_x = z_9 - z_5$ e $G_y = z_8 - z_6$ [22]. Este detector é um dos mais antigos usados no processamento de imagens digitais. É um método simples, mas muito limitado, sendo escolhido para aplicações em que a simplicidade e a velocidade são fatores dominantes. Sua aplicação produz imagens com altos valores de intensidade de cor em regiões de limites bem definidos, e valores baixos onde os limites são suaves. As bordas com inclinação múltipla de 45° não são afetadas, como pode-se ver na figura 2.14.




Figura 2.13: Máscaras do operador de Roberts (adaptado de [22]).



Figura 2.14: Efeito da aplicação do operador de Roberts.

As primeiras derivadas G_x e G_y do operador de Sobel são calculadas pelas máscaras da figura 2.15(b) e (c), sendo $G_x = (z_7 + 2z_8 + z_9) - (z_1 + z_2 + z_3)$ e $G_y = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7)$ [22], [46]. Este operador realça as linhas horizontais e verticais mais escuras do que o fundo, deixando os pontos isolados inalterados. A máscara da figura 2.15(b) detecta as variações no sentido horizontal e a da figura 2.15(c) no sentido vertical.




Figura 2.15: Máscaras do operador de Sobel (adaptado de [22]).

Na figura 2.16(b) e (c) estão os resultados das máscaras horizontal (figura 2.15(b)) e vertical (figura 2.15(c)), respectivamente. Nota-se que os contornos horizontais foram mais realçados quando aplicou-se a máscara horizontal, ao passo que os contornos verticais foram reforçados quando a máscara vertical foi utilizada. O resultado da junção das duas máscaras está na figura 2.16(d).




Figura 2.16: Efeito da aplicação do operador de Sobel.

O operador de Prewitt suaviza a imagem antes de retornar os contornos, atenuando os efeitos negativos do ruído [22]. Este operador é resultado da convolução com as máscaras da figura 2.17, e pode-se observar um exemplo de sua aplicação na figura 2.18.

z1	z2	z3		-1	-1	-1	-1	0	1
z4	z5	z6		0	0	0	-1	0	1
z7	z8	z9		1	1	1	-1	0	1
(a)				(b)					

Figura 2.17: Máscaras de convolução usadas com o operador de Prewitt (adaptado de [22]).




Figura 2.18: Efeito da aplicação do operador de Prewitt.

Em 1986 J. Canny [9] desenvolveu um método para detecção de bordas baseado na utilização de um operador gaussiano. Este método ficou conhecido como detector de Canny, e é uma ferramenta muito usada para determinação de contornos de regiões em processamento de imagens.

O operador de Canny foi desenvolvido com base em critérios de detecção e de localização. Estes, conhecidos como critérios de desempenho, estão sujeitos a avaliação das respostas para que cada borda tenha uma única resposta (critério de múltiplas respostas). O operador de Canny *ótimo* é obtido a partir dos critérios de desempenho e aproximado pela primeira derivada da função gaussiana apresentada na equação 2.6. Esta função é usada por apresentar uma forma analítica simples, e grande eficiência para calcular a extensão bidimensional do filtro devido à sua separabilidade. Para complementar este operador, criou-se o processo conhecido como supressão não máxima para afinamento da borda.

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{\frac{-x^2}{2\sigma^2}}, \quad (2.6)$$

com x sendo um elemento na direção da convolução.

A convolução do operador gaussiano (equação 2.6) com o sinal de entrada reduz as altas frequências da imagem, suavizando-a. As máscaras G_x e G_y usadas, respectivamente, para convolução nas direções x e y , são obtidas a partir da primeira derivada da equação 2.6. Assim,

$$G'(x) = \frac{-x}{\sqrt{2\pi\sigma^3}} e^{\frac{-x^2}{2\sigma^2}}, \quad (2.7)$$

$$G'(y) = \frac{-y}{\sqrt{2\pi\sigma^3}} e^{\frac{-y^2}{2\sigma^2}}, \quad (2.8)$$

onde, σ é o desvio padrão da função gaussiana, e define a forma das máscaras G_x e G_y .

Em seguida, realiza-se a diferenciação e a convolução do filtro gaussiano com a imagem, determinando o gradiente de cada parte desta e suas bordas horizontais e verticais. O algoritmo de Canny pode ser dividido nos passos a seguir:

1. leitura da imagem a ser processada;
2. cálculo da primeira derivada da função gaussiana para criação das duas máscaras unidimensionais, G_x e G_y , usadas para a diferenciação da imagem nas direções x e y , respectivamente.
3. convolução da imagem com G_x ao longo das linhas e G_y ao longo das colunas, gerando duas imagens, aqui chamadas, respectivamente, de I_x e I_y ;
4. cálculo da magnitude de cada pixel (x, y) , usando a equação

$$M(x, y) = \sqrt{I_x(x, y)^2 + I_y(x, y)^2}; \quad (2.9)$$

5. anulamento dos pixels que não são máximos locais na direção perpendicular à borda, produzindo um afinamento das bordas. Este passo é chamado de “supressão não máxima”;
6. limiarização adaptativa baseada em dois limiares (L_1 e L_2). Assim, o algoritmo efetua um processo de complementação das descontinuidades de uma limiarização, aproveitando o resultado da outra.

Após determinar todos os gradientes, localiza-se e mantém apenas aqueles de maior amplitude, de forma a minimizar as bordas indesejáveis da região. Isto é feito pela “supressão não máxima” que reduz a espessura dos contornos. Por fim, efetua-se a limiarização adaptativa, geralmente os limiares são escolhidos de tal forma que $L_1 \cong 2L_2$. Se o valor do pixel da borda for superior ao limiar maior, este é aceito, e se for menor que o limiar menor, o pixel é rejeitado. Para os pixels cujos valores localizam-se entre os dois limiares, são aceitos aqueles que estiverem conectados de forma a se obter uma boa resposta. O resultado deste método é consistente e pode ser visualizado na figura 2.19.




Figura 2.19: Efeito da aplicação do operador de Canny.

Outra categoria de filtros não lineares é a dos filtros morfológicos, que exploram as características geométricas dos níveis de cor da imagem. Neste tipo de filtro, as máscaras passam a se chamar elementos estruturantes e são binárias (seus elementos são compostos por 0 ou 1). O filtro da mediana, a erosão e a dilatação são alguns tipos de filtros morfológicos.

O filtro morfológico da mediana suaviza e elimina ruídos mantendo a dimensão da imagem. A mediana é calculada a partir de um conjunto de pixels pertencentes à vizinhança do ponto analisado e definidos pela matriz de elementos estruturantes. Os elementos estruturantes fazem o papel da máscara. Uma representação gráfica do cálculo da mediana

pode ser vista na figura 2.20. Nesta figura, a parte (a) representa a matriz de elementos estruturantes, denominada aqui por M , as partes (b) e (c) são as imagens de entrada (I) e saída (I_s), respectivamente. Baseando-se nos valores de cada posição de M , é construída uma fila de pontos ordenados por suas respectivas intensidades, como na figura 2.20-(d). O ponto mediano é então escolhido para substituir o ponto em destaque de I , obtendo a cena I_s como resultado. Um exemplo da aplicação deste filtro para redução de ruído, usando a mesma máscara da figura 2.20, está na figura 2.21, onde em (a) tem-se a imagem original e em (b) a imagem após esta operação. Pode-se notar uma boa redução de ruídos, bem como uma perda nos detalhes da rugosidade das bordas.

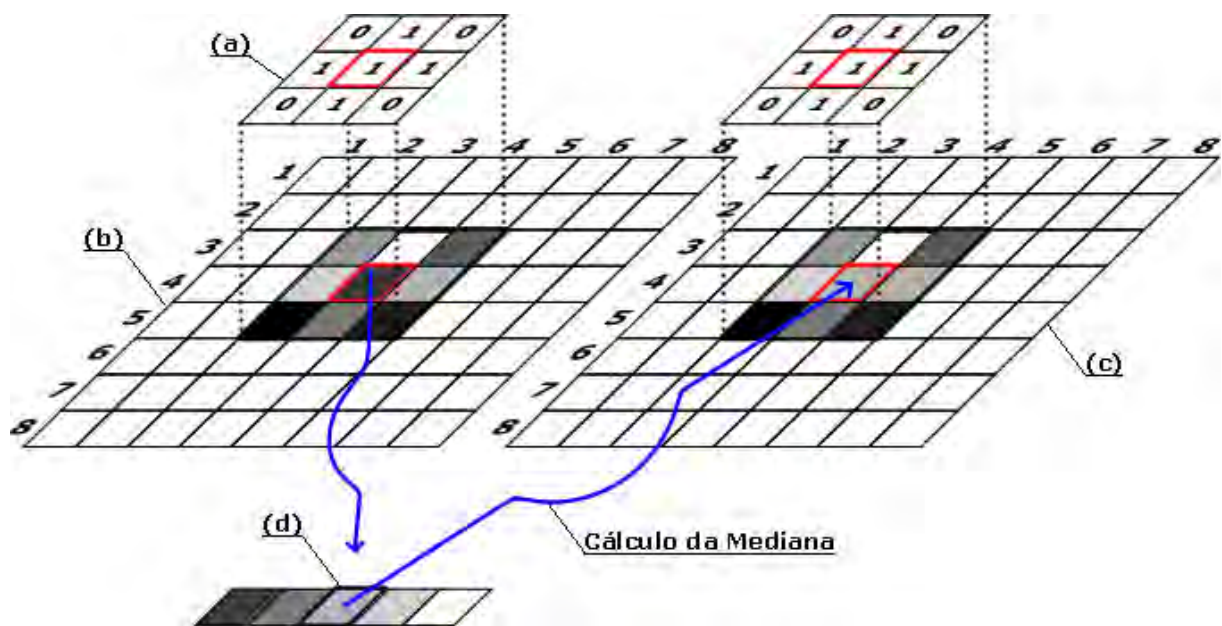


Figura 2.20: Representação do cálculo do filtro morfológico da mediana.




Figura 2.21: Efeito do filtro morfológico da mediana.

O filtro morfológico de erosão provoca um “encolhimento” do objeto, sendo uma trans-

formação morfológica que combina dois conjuntos A (imagem) e B (elemento estruturante). A erosão de A por B pode ser expressa por:

$$A \ominus B = (x | (B)_x \subseteq A) \quad (2.10)$$

onde $(B)_x$ é a translação de B por x .

Assim, o conjunto resultante da erosão de A por B é formado por todos os pontos x , tal que B transladado por x , fique contido no conjunto A . Um exemplo da aplicação deste filtro na imagem (b) da figura 2.22, usando o elemento estruturante da imagem (a), pode ser visto em (d). Nota-se que ocorreu um afinamento do objeto (neste caso o papagaio), provocando a redução dos altos níveis de cinza e tornando a imagem mais escura.




Figura 2.22: Efeito da dilatação (c) e da erosão (d), aplicados sobre a imagem (a).

A dilatação de A por B consiste na expansão do objeto e pode ser expressa por:

$$A \oplus B = (x | (\hat{B})_x \cap A \neq \emptyset), \quad (2.11)$$

onde \hat{B} é a reflexão de B em torno de sua origem e $(\hat{B})_x$ é a translação de \hat{B} por x . Desta forma, o conjunto A dilatado pelo elemento estruturante B , é o conjunto dos pontos x , onde \hat{B} transladado de x e a imagem A se sobreponham em pelo menos um elemento não nulo. Na figura 2.22(c) tem-se o exemplo da dilatação aplicada sobre a imagem (b) usando o elemento estruturante em (a). Neste caso, ocorreu a expansão dos altos níveis de cinza, clareando a imagem.

2.2.5 Representação de fronteiras por assinatura

A assinatura de uma fronteira é a sua representação unidimensional, com o objetivo de facilitar a definição de seu tamanho e do número de concavidades. Uma forma de ser obtida é definir um ponto no centro do contorno, fixar uma linha deste ponto à borda e girar esta linha, até voltar ao ponto de partida. Na figura 2.23, tem-se o exemplo da

extração da assinatura de um quadrado com lado de tamanho A . Pode-se observar que a assinatura permite que a borda seja aberta, facilitando a localização dos pontos onde o contorno muda de direção.




Figura 2.23: Exemplo de assinatura de um quadrado de lado A (adaptado de [22]).

2.2.6 Crescimento de Regiões

O procedimento de crescimento de regiões visa agrupar o maior número de pixels possível em regiões maiores, de acordo com um critério de crescimento pré-definido. A idéia básica é considerar um pixel semente e ir agrupando a ele seus vizinhos que possuam características semelhantes às suas. Quando não tiverem mais pontos com as características da semente conectados àquela região, define-se outra semente que ainda não tenha sido percorrida e inicia-se o processo novamente [10].

A seleção do conjunto de sementes pode ser baseada na natureza do problema. Enquanto isso, a seleção da característica usada para a escolha dos vizinhos a serem adicionados à região do pixel semente, ou seja, o critério de similaridade, depende do problema analisado e de características da imagem, como por exemplo, se a cena é monocromática ou colorida [22].

Na figura 2.24 temos um exemplo de método de crescimento de região usando os pontos semente da figura 2.24 (b) (pontos na cor branca) e um limiar igual a 40 para binarizar a imagem. Vale ressaltar que a intensidade de cor nesta imagem varia de 0(zero)

a 255. O resultado pode ser visto na figura 2.24 (c). Pelo exemplo da figura 2.24 tem-se que o objeto e o fundo foram quase totalmente separados. Apenas o bico da ave e algumas partes do seu pescoço se misturaram com o fundo.




Figura 2.24: Efeito do método de crescimento de regiões.

Crescimento por fusão (*Quadtree*)

Uma alternativa para o método de crescimento de regiões a partir de pontos semente é a subdivisão da imagem em conjuntos de regiões disjuntas. O método de crescimento de regiões por fusão consiste em dividir a cena em quadrantes até que um parâmetro P seja verdadeiro. Desta forma, o método efetua divisões sucessivas, gerando quadrantes cada vez menores até que a condição P seja satisfeita, formando uma árvore onde cada nó não-folha possui 4 filhos (por isso o nome *Quadtree*), como na figura 2.25.




Figura 2.25: Esquema do método Quadtree [22].

Crescimento por *watershed*

Proposta por Digabel e Lantuéjoul [16] e melhorada por Beucher e Lantuéjoul [5], a segmentação por *watershed* é um dos métodos de segmentação por crescimento de regiões mais utilizados. Usando os conceitos de inundação de relevos topográficos, essa abordagem considera que uma imagem pode ser formada como um relevo composto de

vales representando as áreas mais escuras, e montanhas representado as mais claras. Pode ocorrer dois tipos de inundação, uma decorrente da água vinda de cima, como se fosse derramada sobre o relevo, e outra como consequência de furos nas regiões mais baixas, por onde a água entraria após mergulhar o relevo em um reservatório de água [43].

A proposta inicial considera que a inundação acontece com água vinda de cima. Quando uma gota de água cair sobre a superfície, esta vai escorrer para o lado mais íngreme até chegar ao fundo do vale (região de mínimo). A região formada por todos os pontos da superfície onde as gotas escorrem para a mesma região de mínimo é chamada de represa. Por outro lado, todos os pontos onde a gota de água que cair não escorrer, formam as fronteiras das represas e são chamados de *watershed*, ou divisores de água.

Ao ocorrer a inundação, águas de diferentes bacias se encontram nas linhas divisoras de águas, e o processo de inundação é interrompido quando a água atinge o pico máximo do relevo [32]. Assim, a segmentação baseada em *watershed* é uma técnica eficiente para aplicação em imagens de radiografia, tomografia computadorizada, entre outras. Ao ser aplicado em imagens, este método simula uma inundação em uma região, baseando-se na escolha de marcadores rotulados na imagem, a partir dos quais são definidas as regiões que pertencem aos objetos de interesse e ao fundo. Escolhendo-se rótulos distintos, é possível detectar vários objetos simultaneamente [6], [20].

Esta técnica é geralmente aplicada sobre o gradiente morfológico de uma imagem devido ao fato deste operador realçar os contornos da mesma, facilitando o processo de segmentação [45]. É importante suavizar a imagem antes de aplicar o *watershed*, para evitar uma quantidade excessiva de mínimos locais decorrentes da sensibilidade do operador gradiente à presença de ruídos. No entanto, aplicação do *watershed* pode gerar uma segmentação do próprio objeto em diversas sub-regiões. Este efeito é chamado de super-segmentação e pode ser visualizado na figura 2.26. Pode-se notar nesta figura, que na imagem super-segmentada (b), a aplicação do método resultou em um número excessivo de regiões, dificultando a identificação das regiões de interesse corretamente.

A característica básica do gradiente morfológico é que ele representa a transição entre os níveis claro e escuro, sendo maior quanto mais brusca for a transição. O operador de gradiente morfológico de uma imagem é usado para obter o contorno em imagens binárias ou para realçar os contornos em imagens em tons de cinza, e é definido por:

$$g(I) = (I \oplus B) - (I \ominus B), \quad (2.12)$$

onde $g(I)$ é a função gradiente, I é a imagem original, $(I \oplus B)$ é a dilatação ($D_B(I)$) de I

usando o elemento estruturante B e $(I \ominus B)$ é a erosão ($\in_B(I)$) de I usando o elemento estruturante B .




Figura 2.26: Imagem super-segmentada [Adaptado de [38]].

Pode-se definir também os gradientes externo e interno [42]. O gradiente interno, denominado g^- é definido pela equação 2.13, ou seja, é a diferença entre a imagem original e sua erosão, realçando os contornos internos dos objetos da imagem. Ao passo que o gradiente externo g^+ é definido pela equação 2.14, sendo a diferença entre a imagem dilatada e a original, reforçando os contornos externos dos objetos.

$$g^-(I) = I - \in_B(I). \quad (2.13)$$

$$g^+(I) = D_B(I) - I. \quad (2.14)$$

Para evitar o problema da super-segmentação, Meyer e Beucher em [33] propuseram uma adaptação no modelo *watershed* tradicional. Nesta abordagem, são especificados marcadores por onde inicia-se o alagamento, obtendo assim uma bacia de captação para cada marcador. No entanto, o ponto negativo desta abordagem é a definição de quais pontos são necessários para obter o resultado desejado.

Um marcador não necessariamente pertencente a um mínimo local pode ser inserido na imagem. Todos os pontos marcados são perfurados, tornando-se os únicos fluxos de água para inundação. Neste caso, as demais regiões da imagem são fundidas à medida que a inundação acontece, e ao final do processo as *watersheds* são definidas para separar os fluxos provenientes das bacias indicadas pelos marcadores [44].

Existem diversos métodos para segmentação por *watershed*. Suas aplicações dependem

do tipo de imagem processada e também da abordagem adotada no desenvolvimento das técnicas de processamento utilizadas. No entanto, a maioria dos algoritmos de *watershed* baseiam-se no algoritmo recursivo de Vincent e Soille [50] e nas funções de distância entre os níveis de cor de Meyer [32]. Entretanto, se existir a presença de regiões com nível de cor constante na imagem, formando os chamados planaltos, os métodos baseados nas funções de distância de Meyer podem falhar. Neste caso, a distância entre os pixels do planalto é 0(zero), formando linhas divisórias onde não deveriam existir.

Pode-se dizer que o *watershed* é um método morfológico, onde os valores do gradiente dos pixels da imagem são calculados, formando um relevo topográfico com vales e montanhas. Os menores gradientes formam os vales (regiões mais baixas), enquanto os maiores formam as montanhas (regiões mais altas). Os segmentos que formam as bordas são obtidos a partir das últimas regiões de encontro das bacias hidrográficas formadas pela inundação, sendo os pixels destas bacias agrupados a partir da busca de valores próximos de cada mínimo local.

Método de crescimento de regiões de Mumford-Shah

O algoritmo de crescimento de regiões de Mumford-Shah [35] considera que cada região é formada por um conjunto de pixels limitado por uma estrutura elástica, como uma borracha, por exemplo. Assim, as regiões podem crescer enquanto esta borracha for capaz de esticar. A elasticidade da borracha é controlada pela variação entre os pixels da região, de forma que quanto maior for a variação entre os pixels dentro da área envolvida por esta borracha, menor é sua elasticidade. Matematicamente é um algoritmo simples, mas seu custo computacional é elevado. No entanto, é considerado um dos melhores algoritmos da categoria de crescimento de regiões, sendo aplicado principalmente em procedimentos de segmentação que devam ser estáveis e confiáveis [13].

Este método é baseado no funcional (função cujo argumento é uma outra função) da equação 2.15, descrita por Mumford e Shah [35]. Este funcional utiliza a variância dos tons de cinza da imagem como base para seus cálculos. Desta forma, quanto maior a variância do tom de cinza, maior é o número de regiões e mais difícil é a união destas, sendo que a energia do funcional é usada para definir o quanto uma região pode agrupar-se com outras regiões vizinhas.

$$E(\mu, k) = \int \int_{\Omega} ||\mu - g||^2 dx dy + \int \int_{\frac{\Omega}{k}} ||\nabla \mu||^2 dx dy + \lambda l(k), \quad (2.15)$$

onde:

- $E(\mu, k)$ é a energia do funcional de Mumford-Shah em função de μ e da fronteira k ;
- $\mu(x, y)$ é uma função diferenciável dentro de cada região Ω_i ;
- Ω_i é a decomposição da imagem em micro-regiões. $\Omega = \Omega_1 \cup \Omega_2 \cup \dots \cup \Omega_n \cup K$;
- Ω é o domínio da imagem;
- k é a fronteira entre as regiões;
- $g(x, y)$ é o gradiente no ponto (x, y) . O valor de $g(x, y)$ é pequeno dentro de cada região Ω_i e elevado nas regiões de fronteira.
- $l(k)$ é o comprimento total das fronteiras entre as regiões. À medida que as regiões são fundidas este comprimento é reduzido;
- λ é um parâmetro de escala que é incrementado linear ou exponencialmente a cada iteração.

Analisando cada termo da equação 2.15 tem-se:

$\int \int_{\Omega} ||\mu - g||^2 dx dy$: usada para medir se $\mu(x, y)$ é uma boa aproximação de $g(x, y)$.

Quanto melhor for esta aproximação, menor é a contribuição deste termo para o valor da energia. Isso indica que as regiões são semelhantes e podem ser unidas.

$\int \int_{\Omega} ||\nabla \mu||^2 dx dy$: calcula a variação mínima de $\mu(x, y)$ em cada região sem a borda.

\bar{k}

Costuma-se usar a função $\mu(x, y)$ como sendo o valor médio dos pontos de $g(x, y)$ dentro da região, ou seja, um valor constante. Nestes casos, este termo é considerado nulo.

$\lambda l(k)$: o último termo da equação calcula o comprimento das fronteiras multiplicado por um parâmetro de escala λ . Fronteiras com comprimento maior implicam em maior contribuição deste termo para o valor da energia.

Uma variação do modelo de Mumford-Shah é apresentado na equação 2.16. Este modelo é conhecido como energia simplificada de Mumford-Shah.

$$E(k) = \int \int_{\Omega} ||\mu - g||^2 dx dy + \lambda l(k). \quad (2.16)$$

Para esta versão simplificada do funcional assume-se que $\mu(x, y)$ seja uma função constante dentro de cada região, dado pela média dos valores de $g(x, y)$ nesta região.

Assim, a energia simplificada fica apenas em função das fronteiras das regiões, ou seja, de k .

O algoritmo de Mumford-Shah realiza uma análise das regiões, de forma a buscar aquelas que são aptas a se unirem. Isto é feito através do uso da equação do funcional, verificando a variância dos tons de cinza na imagem. Assim, quanto maior for a variância entre as regiões, menor é a probabilidade delas serem unidas. Por outro lado, quando há similaridade de cor, as regiões são acopladas umas nas outras.

A componente λ do funcional de Mumford-Shah define a quantidade de energia que pode ser usada para unir as regiões de uma imagem. Portanto, quando não for mais possível juntar nenhuma região, pode-se variar o valor de λ . Vale ressaltar que este valor depende das imagens a serem manipuladas[35].

Para implementação computacional do método de crescimento de regiões usando o funcional de Mumford-Shah deve-se usar uma versão discretizada da equação 2.16. Para tal, deve haver uma compensação da energia conforme as regiões são agrupadas e aumentem de tamanho. Esta compensação pode ser definida através de um fator de área, aumentando a resistência à fusão para as regiões maiores e reduzindo para as menores.

Considerando R_i e R_j duas regiões adjacentes, $\partial(R_i, R_j)$ a fronteira que as separa e $E(\mu, k)$ o valor da energia, uma nova segmentação (μ', k') é obtida removendo-se a fronteira comum $\partial(R_i, R_j)$, ou seja, $(\mu', k') = (\mu, k) - \partial(R_i, R_j)$. Calcula-se a energia da nova segmentação $(E(\mu', k'))$ e a compara com a energia anterior $(E(\mu, k))$. Este cálculo é feito para todas as regiões vizinhas de R_i e R_j , ocorrendo a união das regiões onde a diferença das duas energias for maior, e a energia da nova segmentação for menor do que da região anterior. Caso não se encontre nenhuma região adjacente que provoque redução de energia, nenhuma das regiões processadas são unidas, passando para análise das regiões seguintes. Quando toda a imagem for percorrida e não for mais possível juntar nenhuma região, o valor de λ pode ser aumentado e a imagem percorrida novamente.

Desta forma, o critério para unir duas regiões R_i e R_j depende do sinal de:

$$E(k) > \partial(R_i, R_j) - E(k). \quad (2.17)$$

Assim, a equação que descreve o critério de união fica definida por:

$$E(E(k) - \partial(R_i, R_j)) = \frac{|R_i||R_j|}{|R_i| + |R_j|} \|\mu_i - \mu_j\|^2 - \lambda(\partial(R_i, R_j)), \quad (2.18)$$

onde:

- $|R_i|$ é a área da região R_i ;
- $|R_j|$ é a área da região R_j ;
- μ_i é a intensidade da região i ;
- μ_j é a intensidade da região j e,
- $l(\partial(R_i, R_j))$ é o comprimento da fronteira entre as regiões R_i e R_j .

Merge (União)

Como discutido na seção anterior, o procedimento de crescimento de regiões divide a cena em vários conjuntos de pixels. Alguns destes conjuntos possuem características semelhantes e, dependendo da aplicação, podem ser agrupados sem provocar perda na caracterização da imagem. O método *merge* faz esta união tomando por base parâmetros pré-definidos, como a média da intensidade de cor de cada região, a textura, a tonalidade das bordas, dentre outros.

A escolha dos parâmetros de união depende da aplicação desejada. Na detecção de tumores de pele, por exemplo, pode-se utilizar a média da intensidade de cor das regiões vizinhas, pois este componente varia em relação à parte saudável e à parte doente, podendo juntar as regiões onde a variação é mínima [10].

2.2.7 Quantização de cores

Imagens coloridas geralmente possuem centenas (ou milhares) de cores que dificultam o processo de segmentação. A quantização é uma técnica usada para reduzir a quantidade de cores de uma cena. O procedimento de quantização pode ser definido por dois passos: (a) divisão do espaço de cores em intervalos e (b) substituição da intensidade de cada pixel pelo menor valor do intervalo, ao qual ele pertence.

Assim, a quantidade de cores da imagem quantizada é igual ao número de intervalos, no qual o espaço de cores foi dividido. Podemos ver um exemplo de quantização de cores na figura 2.27, na qual percebe-se que as cores mais próximas foram padronizadas, formando grupos de pixels de mesma cor.




Figura 2.27: Resultado da aplicação do método de quantização de cores. Em (a) a imagem original com 55.664 cores e em (b) a imagem quantizada com 155 cores.

2.2.8 Segmentação de imagens

A segmentação de imagens consiste em extrair objetos ou características de um cenário. A precisão deste processo depende de fatores como a quantidade de ruído na cena, o contraste, a textura e a cor. Segmentar imagens com precisão é uma das tarefas mais difíceis e importantes do processamento de imagens, pois pode determinar o sucesso ou falha dos procedimentos de análise computadorizada.

Em imagens monocromáticas, o procedimento de segmentação baseia-se na similaridade e descontinuidade das intensidades dos níveis de cinza. A similaridade considera a semelhança com uma característica pré-definida, enquanto a descontinuidade divide a imagem a partir de mudanças abruptas nos níveis de cinza, sendo esta última muito usada na separação das bordas dos objetos.

Na figura 2.28, tem-se a ilustração da relação do procedimento de segmentação, dentro da sequência de passos do processamento de imagens. Antes de segmentar uma cena, é importante fazer o pré-processamento para que a segmentação seja precisa. É nesta etapa que os filtros para remoção de ruídos são aplicados, é feita a quantização de cores e/ou a cena é realçada.

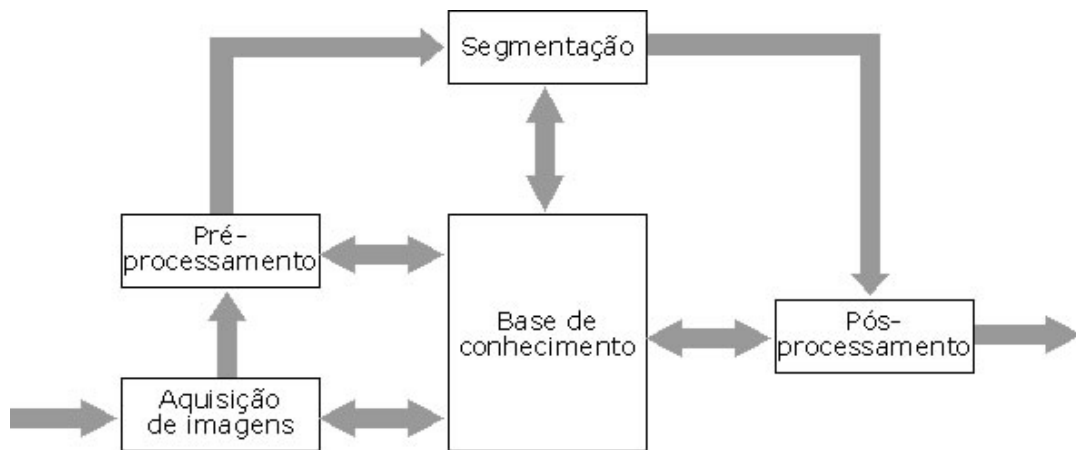


Figura 2.28: Relação entre pré-processamento, segmentação e pós-processamento.

A segmentação extrai as características desejadas da imagem e o pós-processamento se encarrega de reconhecer, interpretar e descrever o que foi obtido pela segmentação.

2.3 Contornos ativos (*Snakes*)

Os modelos de contorno ativo foram introduzidos por Kass, Within e Terzoupoulos na década de 80 [27]. Desde então, estes modelos têm se tornado uma ferramenta importante, para segmentação no processamento de imagens digitais. A idéia básica desta técnica é definir uma curva inicial fechada, dentro do domínio da imagem, e deformá-la em direção à borda desejada pela ação de forças internas e externas à curva. Esta deformação é obtida a partir da minimização da energia da curva inicial, com o objetivo de torná-la mínima, quando esta estiver sobre uma região com as características pretendidas para extração, ou seja, o resultado deste processo retorna informações sobre a forma e a posição da borda na imagem. Portanto, estes modelos têm grande aplicação em segmentação de imagens médicas [28], [29], [47].

2.3.1 Representação de contorno ativo

Geometricamente, um *snake* é um contorno embutido em uma imagem, que pode ser representada parametricamente como $v(s) = (x(s), y(s))$, onde $s \in [0, 1]$ e é o domínio paramétrico, e x e y são funções que representam as coordenadas. Este contorno movimenta-se no domínio de uma imagem I no plano $(x, y) \in R^2$ [30], e a sua forma final corresponde à mínima energia do funcional da equação 2.19. Este funcional foi definido por Kass,

Witkin e Terzopoulos em [27]:

$$E_{snake} = \int_0^1 E_{int}(v(s))ds + \int_0^1 E_{imagem}(v(s))ds + \int_0^1 E_{res}(v(s))ds, \quad (2.19)$$

onde E_{int} é a energia interna referente à deformação da curva, regularizando e quantificando a deformação de um contorno elástico. E_{imagem} é a energia dependente da imagem onde o contorno ativo está inserido e, E_{res} é a energia obtida por alguma restrição externa.

Alguns autores como Ballerini [2], Dumitras [19] e Xu [51] utilizam o termo energia externa, E_{ext} , para representar toda a energia proveniente da imagem. Esta abordagem foi adotada neste trabalho. Desta forma, a equação 2.19 passa a ficar como na equação 2.20:

$$E_{snake} = \int_0^1 E_{int}(v(s))ds + \int_0^1 E_{ext}(v(s))ds. \quad (2.20)$$

A seguir aborda-se com mais detalhes as energias interna e externa do contorno ativo.

Energia interna (E_{int})

No modelo de contorno ativo, a energia interna atua na manutenção da suavidade da curva, quando esta sofrer as ações do campo de força externa. Esta energia é definida pela equação 2.21:

$$E_{int} = \frac{1}{2} \left[\alpha \left| \frac{\partial v(s)}{\partial s} \right|^2 + \beta \left| \frac{\partial^2 v(s)}{\partial s^2} \right|^2 \right]. \quad (2.21)$$

Os termos α e β são parâmetros usados para controlar, respectivamente, a elasticidade e a rigidez da curva. Assim, o primeiro termo da equação controla a elasticidade da curva, dando o comportamento de uma membrana elástica, se deformando à medida que um conjunto de forças externas age sobre ela. Para valores altos de α , a curva tende a se expandir, bem como se contrair para valores baixos. Já o segundo termo está relacionado com a resistência à deformação da curva, evitando que descontinuidades sejam geradas. Se o valor de β for alto, o “contorno” tende a sofrer suavizações.

A escolha errada destes parâmetros pode prejudicar o desempenho do método de segmentação. Como exemplo, podem ocorrer descontinuidades no contorno caso ambos os parâmetros α e β sejam nulos, ou ocorrer suavização excessiva e perda de detalhes de rugosidade da borda caso β seja muito alto. Por isso, muitas abordagens consideram estes parâmetros constantes.

Energia externa (E_{ext})

O contorno ativo é arrastado (ou empurrado) para as características de interesse (bordas, regiões de interesse) devido à ação da energia externa. Portanto, a função a representar esta energia deve ser formulada de acordo com a característica de interesse. Como exemplo, os funcionais das equações 2.22 e 2.23 atraem o contorno ativo para linhas e bordas na imagem, respectivamente [14]:

$$E_{linha}(v(s)) = I(v(s)), \quad (2.22)$$

$$E_{borda}(v(s)) = |\nabla I(v(s))|^2. \quad (2.23)$$

Um filtro para eliminação de ruído pode ser adicionado na equação da energia externa, aumentando a distância com que a borda é percebida pelo contorno ativo e o seu alcance de captura. Tomando a equação 2.23 para representar a energia externa do modelo e adicionando um filtro gaussiano, tem-se a nova equação externa dada por:

$$E_{ext}(x(s), y(s)) = -|\nabla G_\sigma I(x(s), y(s))|^2, \quad (2.24)$$

sendo $I(x(s), y(s))$ é a imagem processada, G_σ é um filtro gaussiano bidimensional com desvio padrão σ e ∇ é o operador gradiente.

Minimização da energia no modelo tradicional

A equação 2.19 pode ser reescrita da seguinte maneira:

$$E(v(s)) = \frac{\alpha}{2} \int_0^1 \left| \frac{\partial v(s)}{\partial s} \right|^2 ds + \frac{\beta}{2} \int_0^1 \left| \frac{\partial v(s)}{\partial s} \right|^2 ds + \int_0^1 P(v(s)) ds, \quad (2.25)$$

onde P denota uma função indicadora de bordas, ou seja, retorna valores próximos de 0(zero) em pontos próximos às bordas da imagem, aumentando seus valores à medida que se distancia das bordas.

O funcional desta equação é da forma:

$$J = \int_{x_0}^{x_1} F(y, y', x) dx. \quad (2.26)$$

Consequentemente, a equação de Euler-Lagrange [14], correspondente para a loca-

lização de extremos, tem a forma geral da equação 2.27:

$$\frac{\partial F}{\partial x} - \left(\frac{\partial F}{\partial x'} \right) \frac{\partial}{\partial s} + \left(\frac{\partial F}{\partial x''} \right) \frac{\partial^2}{\partial s^2} = 0, \quad (2.27)$$

onde:

- $x \equiv v(s)$,
- $x' \equiv \frac{\partial v(s)}{\partial s}$ e,
- $x'' \equiv \frac{\partial^2 v(s)}{\partial s^2}$.

O funcional F é a representação da energia potencial, elasticidade e rigidez de um contorno ativo. Portanto:

$$F = P(x) + \frac{\alpha}{2} x'^2 + \frac{\beta}{2} x''^2. \quad (2.28)$$

Considerando α e β constantes e as derivadas parciais da equação 2.27, tem-se as seguintes soluções:

$$\begin{aligned} \frac{\partial F}{\partial x} &= \frac{\partial P}{\partial x} \\ \frac{\partial F}{\partial x'} &= \alpha x' \\ \frac{\partial F}{\partial x''} &= \beta x'' \end{aligned} \quad (2.29)$$

Portanto, um contorno $v(s)$ que solucionar a equação 2.30, também minimiza a energia do contorno ativo E_{snake} .

$$\frac{\partial v(s)}{\partial t} = \alpha \frac{\partial^2 v(s)}{\partial s^2} - \beta \frac{\partial^4 v(s)}{\partial s^4} - \frac{\partial P}{\partial v(s)}. \quad (2.30)$$

Discretização do modelo tradicional por diferenças finitas

Para ser resolvida computacionalmente, a equação 2.30 deve ser discretizada e resolvida de forma aproximada. Para isso, pode-se utilizar o modelo baseado nas diferenças finitas [1]. Dividindo $v(s)$ nas suas componentes x e y e determinando u_j (onde $0 \leq j \leq n-1$),

como aproximação discreta para $x(s)$ e $y(s)$, pode-se reescrever a equação 2.30 como:

$$\frac{\partial u_j}{\partial t} = \alpha \frac{\partial^2 u_j}{\partial s^2} - \beta \frac{\partial^4 u_j}{\partial s^4} - \frac{\partial P}{\partial u_j}. \quad (2.31)$$

Utilizando o método de diferenças finitas, pode-se estimar as derivadas parciais para um instante de tempo seguinte. Denotando a iteração por t , estas derivadas são representadas como:

$$\begin{aligned} \frac{\partial u}{\partial t} &= \frac{u_j^{t+1} - u_j^t}{\Delta t}, \\ \frac{\partial^2 u}{\partial s^2} &= \frac{u_{j+1}^{t+1} - 2u_j^{t+1} + u_{j-1}^{t+1}}{t + 1\Delta t^2}, \\ \frac{\partial^4 u}{\partial s^4} &= \frac{u_{j+2}^{t+1} - 4u_{j+1}^{t+1} + 6u_j^{t+1} - u_{j-2}^{t+1}}{\Delta s^4}. \end{aligned} \quad (2.32)$$

Substituindo na equação 2.31 os termos da equação 2.32 e agrupando os termos em função de j e t , tem-se:

$$\begin{aligned} u_j^t + \Delta t \frac{\partial P}{\partial u_j^t} &= \beta \frac{\Delta t}{\Delta s^4} u_{j+2}^{t+1} - \left(\alpha \frac{\Delta t}{\Delta s^2} + 4\beta \frac{\Delta t}{\Delta s^4} \right) u_{j+1}^{t+1} + \beta \frac{\Delta t}{\Delta s^4} u_{j-2}^{t+1} \\ &+ \left(1 + 2\alpha \frac{\Delta t}{\Delta s^2} + 6\beta \frac{\Delta t}{\Delta s^4} \right) u_j^{t+1} - \left(\alpha \frac{\Delta t}{\Delta s^2} + 4\beta \frac{\Delta t}{\Delta s^4} \right) u_{j-1}^{t+1}. \end{aligned} \quad (2.33)$$

Limitações do modelo tradicional

Os contornos ativos se deformam sobre a imagem, tentando ajustar-se à borda procurada. No entanto, para processar imagens sem interação do usuário, este modelo possui algumas limitações. O contorno inicial usado como ponto de partida deve estar localizado próximo ao objeto de interesse para garantir um bom desempenho. Por se tratar de um sistema de otimização, o contorno ativo não garante que a solução encontrada seja o mínimo global, ou seja, neste caso não garante que a borda resultante do processamento seja a ideal. A escolha errada dos parâmetros de rigidez e elasticidade podem limitar a flexibilidade do contorno ativo, impedindo a representação de formas tubulares. Além disso, a topologia do objeto procurado deve ser previamente conhecida porque este modelo original não altera a topologia durante sua deformação [30]. Desta forma, vale ressaltar que estes fatores podem provocar a convergência do contorno para um mínimo local.

As energias internas e externas também podem interferir negativamente no desempenho deste modelo. A energia externa define o tamanho do passo de deslocamento dado pelo contorno ativo. Valores muito altos para esta energia podem fazer com que o des-

locamento ocorra com passos muito largos, podendo ultrapassar o contorno procurado, enquanto energia externa muito baixa pode manter o contorno estagnado. Por outro lado, a energia interna, que é responsável por manter a suavidade da curva, pode forçar a convergência a um segmento de reta, caso a energia externa não tenha força suficiente para manter o equilíbrio do sistema de forças [12]. Portanto, os pontos negativos descritos deixam claro que este modelo original é muito sensível à inicialização do contorno ativo, assim como a impossibilidade de alteração topológica da curva.

Contorno ativo baseado no fluxo do vetor gradiente

O uso do fluxo do vetor gradiente (GVF) como força externa para o modelo de contorno ativo foi proposto por Xu e Prince [51], [52]. Esta abordagem se constitui em um conjunto de campos vetoriais usado como força externa no modelo de contorno ativo. Seu desenvolvimento foi motivado, principalmente para amenizar o problema de convergência para mínimos locais em imagens com a presença de ruído, e para representar com maior eficiência as concavidades existentes nas bordas dos objetos. A idéia desta abordagem é aumentar a faixa de atuação da força externa, estendendo-a para longe dos objetos e guiando a curva em direção à borda. Assim, as linhas de força deixam de convergir para as bordas dos objetos apenas na sua vizinhança.

O campo vetorial do GVF pode ser definido como

$$V(x, y) = [u(x, y), v(x, y)], \quad (2.34)$$

e minimiza a energia do funcional:

$$E = \int \int \mu(u_x^2 + u_y^2 + v_x^2 + v_y^2) + |\nabla I|^2 |v - \nabla I|^2 dx dy, \quad (2.35)$$

onde:

- ∇I é uma função gradiente da imagem;
- μ é um parâmetro de equilíbrio entre o primeiro e segundo termos da equação. Foi adotado como sendo constante neste trabalho.

De acordo com a análise feita por XU e Prince [51], [52], quando o valor da expressão $|\nabla I|$ for pequeno, a energia é determinada pelas derivadas parciais dos campos do vetor. Caso contrário, o segundo termo torna-se dominante na equação, e pode ser minimizado adotando $v = \nabla I$.

Usando o cálculo variacional [1], o GVF pode ser resolvido pela solução das equações de Euler seguintes:

$$\mu \nabla^2 u - (u - I_x)(I_x^2 + I_y^2) = 0, \quad (2.36)$$

$$\mu \nabla^2 v - (v - I_y)(I_x^2 + I_y^2) = 0, \quad (2.37)$$

onde ∇^2 é o operador Laplaciano e I_x e I_y são, respectivamente, as componentes x e y da imagem I .

Nas regiões homogêneas da imagem ($I(x, y)$ é constante), o segundo termo das duas equações é nulo, devido ao gradiente de $I(x, y)$ ser 0(zero). Portanto, u e v são determinados por seus Laplacianos nestas regiões, resultando em uma informação adicional à retornada pelas regiões das bordas.

Considerando u e v como funções do tempo, as equações 2.36 e 2.37 podem ser resolvidas como a seguir:

$$u_t(x, y, t) = \mu \nabla^2 u(x, y, t) - (u(x, y, t) - I_x(x, y))(I_x(x, y)^2 + I_y(x, y)^2), \quad (2.38)$$

$$v_t(x, y, t) = \mu \nabla^2 v(x, y, t) - (v(x, y, t) - I_y(x, y))(I_x(x, y)^2 + I_y(x, y)^2). \quad (2.39)$$

A solução de estado estacionário (com $t \rightarrow \infty$) destas equações é a solução desejada para as equações 2.36 e 2.37. As equações 2.38 e 2.39 são chamadas de equações de difusão generalizada, sendo usadas em vários campos, como condução de calor, fluxo de fluido e para descrição de campos de força externa para modelos de contornos ativos [52].

Usando diferenças centrais, as equações 2.38 e 2.39 podem ser reescritas, respectivamente como:

$$u_t(x, y, t) = \mu \partial^2 u(x, y, t) - b(x, y)u(x, y, t) + c^1(x, y), \quad (2.40)$$

$$v_t(x, y, t) = \mu \partial^2 v(x, y, t) - b(x, y)v(x, y, t) + c^2(x, y), \quad (2.41)$$

onde:

- $b(x, y) = I_x(x, y)^2 + I_y(x, y)^2$;
- $c^1(x, y) = b(x, y)I_x(x, y)$ e,
- $c^2(x, y) = b(x, y)I_y(x, y)$.

Vale ressaltar que as componentes I_x e I_y podem ser calculadas pelo operador gradiente. As componentes $b(x, y)$, $c^1(x, y)$ e $c^2(x, y)$ podem ser calculadas por um processo

iterativo. Para isto, consideram-se os índices i, j e n correspondendo a x, y e t , respectivamente, o espaçamento entre os pixels definido por Δx e Δy e a variação de tempo em cada iteração dada por Δt . Assim, as derivadas parciais requeridas podem ser aproximadas por:

$$\begin{aligned} u_t &= \frac{1}{\Delta t} (u_{i,j}^{t+1} - u_{i,j}^t), \\ v_t &= \frac{1}{\Delta t} (v_{i,j}^{t+1} - v_{i,j}^t), \end{aligned} \quad (2.42)$$

$$\begin{aligned} \nabla^2 u &= \frac{1}{\Delta x \Delta y} (u_{i+1,j} + u_{i,j+1} + u_{i-1,j} + u_{i,j-1} - 4u_{i,j}), \\ \nabla^2 v &= \frac{1}{\Delta x \Delta y} (v_{i+1,j} + v_{i,j+1} + v_{i-1,j} + v_{i,j-1} - 4v_{i,j}). \end{aligned} \quad (2.43)$$

Substituindo as aproximações da equação 2.43 nas equações 2.40 e 2.41, respectivamente, tem-se a solução iterativa para os campos de força externa do modelo GVF. O resultado desta substituição pode ser visto nas equações a seguir:

$$\begin{aligned} u_{i,j}^{t+1} &= (1 - b_{i,j} \Delta t) u_{i,j}^t + \frac{\mu \Delta t}{\Delta x \Delta y} (u_{i+1,j}^t + u_{i,j+1}^t + u_{i-1,j}^t + u_{i,j-1}^t - 4u_{i,j}^t) + c_{i,j}^1 \Delta t, \\ v_{i,j}^{t+1} &= (1 - b_{i,j} \Delta t) v_{i,j}^t + \frac{\mu \Delta t}{\Delta x \Delta y} (v_{i+1,j}^t + v_{i,j+1}^t + v_{i-1,j}^t + v_{i,j-1}^t - 4v_{i,j}^t) + c_{i,j}^2 \Delta t. \end{aligned} \quad (2.44)$$

2.4 Suavização de imagens usando difusão anisotrópica

A suavização usando difusão anisotrópica tem ganhado espaço no processamento de imagens, pois permite a execução de uma suavização seletiva retardando seu efeito sobre as regiões de interesse na imagem, ou seja, as bordas. Um dos modelos mais promissores para suavização nesta categoria foi proposto em 2003 por Barcelos, Boaventura e Silva [3] e, desde então vem sendo utilizado com sucesso em várias aplicações [40].

A idéia de usar a difusão não linear para suavização seletiva de imagens surgiu inicialmente com Perona e Malik [39]. Com o objetivo de tornar a equação proposta por estes pesquisadores mais balanceada, Barcelos e colaboradores [3] propuseram a inserção de um termo para fazer o balanceamento entre o termo forçante adicionado por Nordström [36]

e o termo de difusão. O modelo proposto é definido na equação 2.45 [3]:

$$u_t = g |\nabla u| \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) - \lambda(1 - g)(u - I), \quad (2.45)$$

onde I é a imagem original, u é sua versão suavizada, λ é um parâmetro que auxilia na velocidade da difusão, $(u - I)$ é o termo forçante proposto por Nordström [36] e $(1 - g)$ é o termo de moderação proposto por Barcelos e colaboradores [3]. Desta forma, este termo de balanceamento em função de g , permite que as regiões que demandam maior suavização ($g \sim 1$) sejam mais fortemente suavizadas, enquanto retarda o efeito da remoção de ruídos nas regiões do contorno ($g \sim 0$).

Os demais termos que aparecem neste modelo são:

- $u(x, y, 0) = I(x, y)$, sendo $(x, y) \in R^2$;
- t é o tamanho do passo da evolução temporal;
- ∇ é o operador gradiente; e
- div é o operador divergente.

O termo g da equação é uma função de suavização gaussiana, tal que $g(0) = 1$, $g(s) \geq 0$ e $g(s) \rightarrow 0$ quando $s \rightarrow \infty$, como por exemplo:

$$g = \frac{1}{1 + k|\nabla(G_T u)|^2}, \quad (2.46)$$

com k sendo um parâmetro constante e G_T uma função gaussiana.

Para ser implementada computacionalmente, a equação 2.45 deve ser discretizada, tornando o problema finito, e então permitindo uma solução computacional. Isto pode ser obtido por aproximações numéricas feitas através de métodos de diferenças finitas, onde as derivadas parciais da equação diferencial são aproximadas por diferenças entre os valores da solução discretizada.

O produto de convolução $|\nabla(G_T u)|$ faz parte da equação 2.46, e é usado para encontrar uma média ponderada dos níveis de cores na vizinhança de um determinado pixel. Tomando $\operatorname{conv}(i, j) = (G_T u)(i, j)$, com conv denotando o produto de convolução, e usando o operador de diferenças centradas no cálculo das derivadas de primeira ordem [1], tem-se:

$$\frac{\partial \operatorname{conv}(i, j)}{\partial x} \cong \frac{\operatorname{conv}(i+1, j) - \operatorname{conv}(i-1, j)}{2} = c_1 \quad (2.47)$$

e

$$\frac{\partial conv_{(i,j)}}{\partial y} \cong \frac{conv_{(i,j+1)} - conv_{(i,j-1)}}{2} = c_2. \quad (2.48)$$

Com isso, obtém-se a expressão:

$$\begin{aligned} \nabla(G_T u) &= \left(\frac{\partial conv}{\partial x}, \frac{\partial conv}{\partial y} \right) \Rightarrow \\ |\nabla(G_T u)| &= \sqrt{\left(\frac{\partial conv}{\partial x} \right)^2 + \left(\frac{\partial conv}{\partial y} \right)^2} \Rightarrow \\ |\nabla(G_T u)| &= \sqrt{\left(\frac{\partial G_T u}{\partial x} \right)^2 + \left(\frac{\partial G_T u}{\partial y} \right)^2} \Rightarrow \\ |\nabla(G_T u)| &= \sqrt{c_1^2 + c_2^2} \Rightarrow \\ |\nabla(G_T u)|^2 &= c_1^2 + c_2^2. \end{aligned} \quad (2.49)$$

Usando o resultado da equação 2.49 na função g , tem-se

$$g = \frac{1}{1 + k(c_1^2 + c_2^2)}, \quad (2.50)$$

onde k é uma constante.

Outro termo da equação diferencial a ser discretizado é o termo de difusão $|\nabla u| \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right)$. Esta discretização pode ser obtida usando diferenças centradas.

Pelos operadores de diferenças centradas, tem-se:

$$\begin{aligned} (u_x) &\cong \frac{u_{(i+1,j)} - u_{(i-1,j)}}{2}, \\ u_y &\cong \frac{u_{(i,j+1)} - u_{(i,j-1)}}{2}. \end{aligned} \quad (2.51)$$

Pela derivada parcial mista, pode-se definir u_{xy} como sendo:

$$\begin{aligned} u_{xy} &= \frac{(u_x)_{j+1} - (u_x)_{j-1}}{2} \cong \frac{\frac{u_{(i+1,j+1)} - u_{(i-1,j+1)}}{2} - \frac{u_{(i+1,j-1)} - u_{(i-1,j-1)}}{2}}{2} \Rightarrow \\ u_{xy} &= \frac{u_{(i+1,j+1)} - u_{(i-1,j+1)} - u_{(i+1,j-1)} + u_{(i-1,j-1)}}{4}. \end{aligned} \quad (2.52)$$

Usando as derivadas de segunda ordem em relação a x e y , obtém-se u_{xx} e u_{yy} :

$$\begin{aligned} u_{xx} &= u_{(i+1,j)} - 2u_{(i,j)} + u_{(i-1,j)}, \\ u_{yy} &= u_{(i,j+1)} - 2u_{(i,j)} + u_{(i,j-1)}. \end{aligned} \quad (2.53)$$

Como nas fronteiras da imagem não há pontos suficientes para utilização das diferenças centradas, foram usadas condições de contorno de Neumann $\left(\frac{\partial u}{\partial x} = 0, \frac{\partial u}{\partial y} = 0\right)$ nos pontos destas regiões. Para discretizá-las utilizou-se os operadores de diferenças avançadas e atrasadas, dados respectivamente por:

$$\begin{aligned} u_x &= u_{(i+1,j)} - u_{(i,j)} \text{ e } u_y = u_{(i,j+1)} - u_{(i,j)}, \\ u_x &= u_{(i,j)} - u_{(i-1,j)} \text{ e } u_y = u_{(i,j)} - u_{(i,j-1)}. \end{aligned} \quad (2.54)$$

Assim, desenvolvendo o termo de difusão tem-se:

$$|\nabla u| \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) = \frac{u_x^2 u_{yy} - 2u_x u_y u_{xy} + u_y^2 u_{xx}}{u_x^2 + u_y^2}. \quad (2.55)$$

Este modelo apresenta uma evolução temporal caracterizada por um processo iterativo, onde $u_t = \frac{\partial u}{\partial t}$. Assim, uma aproximação numérica da equação 2.45 [3] em relação ao tempo, é dada pela equação a seguir (adaptada de [4]):

$$\begin{aligned} u_{ij}^{t+1} &= u_{ij}^t + \Delta t \left[g \frac{\left(\frac{u_{i+1j}^t - u_{i-1j}^t}{2} \right)^2 (u_{ij+1}^t - 2u_{ij}^t + u_{ij-1}^t)}{\left(\frac{u_{i+1j}^t - u_{i-1j}^t}{2} \right)^2 + \left(\frac{u_{ij+1}^t - u_{ij-1}^t}{2} \right)^2} \right] \\ &\quad - \Delta t \left[g \frac{(u_{i+1j}^t - u_{i-1j}^t) (u_{ij+1}^t - u_{ij-1}^t) \left(\frac{u_{i+1j+1}^t - u_{i+1j-1}^t - u_{i-1j+1}^t + u_{i-1j-1}^t}{2} \right)}{\left(\frac{u_{i+1j}^t - u_{i-1j}^t}{2} \right)^2 + \left(\frac{u_{ij+1}^t - u_{ij-1}^t}{2} \right)^2} \right] \\ &\quad + \Delta t \left[g \frac{\left(\frac{u_{ij+1}^t - u_{ij-1}^t}{2} \right)^2 (u_{i+1j}^t - 2u_{ij}^t + u_{i-1j}^t)}{\left(\frac{u_{i+1j}^t - u_{i-1j}^t}{2} \right)^2 + \left(\frac{u_{ij+1}^t - u_{ij-1}^t}{2} \right)^2} - \lambda(1-g)(u_{ij}^t - I) \right], \end{aligned} \quad (2.56)$$

onde I é a imagem original, $u_{(i,j)}^{t+1}$ representa a intensidade (i, j) da imagem suavizada no estágio de tempo $t+1$, com $t=1, 2, \dots, N$, e g é definido pela equação 2.46.

Tomando uma imagem I , e aplicando iterativamente a equação 2.56 em todos os seus pontos (i, j) , obtém-se a imagem suavizada seletivamente. Vale ressaltar que o número de iterações aplicadas, deve ser definido de acordo com a quantidade de ruído presente na imagem. A cada iteração, a quantidade de ruído na cena é reduzida. Assim, se a equação de difusão anisotrópica for aplicada em excesso, as bordas passam a ser consideradas ruído

e eliminadas.

No capítulo 3, apresenta-se a descrição de uma abordagem desenvolvida para aproximar a quantidade de iterações, que são usadas na suavização das imagens de lesões de pele. Além disso, o próximo capítulo também descreve todos os passos do método de extração e caracterização automática de bordas de tais lesões, desenvolvido neste trabalho.

3 Método desenvolvido

Este capítulo apresenta os detalhes de implementação do método desenvolvido e suas principais características. As imagens de lesões de pele são geralmente coloridas e variadas, com diferentes formas e intensidades de ruído, como pêlos, bolhas e interferência da iluminação, dificultando sua caracterização visual. Desta forma, pode-se utilizar um filtro usando a teoria de difusão anisotrópica para amenizar a ação destas interferências, preservando ao máximo as bordas das regiões doentes. A extração das bordas das lesões, também é importante para facilitar a análise da rugosidade do contorno das regiões doentes pelo dermatologista. Para tal, outras técnicas de processamento de imagens digitais são aplicadas, tais como crescimento de regiões, contornos ativos, dentre outras.

Na figura 3.1 tem-se o diagrama de fluxo do método desenvolvido. Tal método foi baseado nos passos fundamentais do processamento de imagens digitais para segmentação. A imagem original é pré-processada aplicando-se o modelo de difusão anisotrópica proposto por Barcelos e colaboradores [3] para redução do ruído presente na cena, retardando o efeito degenerativo da difusão nas regiões do contorno das lesões. Isso facilita a etapa seguinte (segmentação), que inicia-se com a aplicação do crescimento de regiões baseando-se na intensidade de cor dos pixels da imagem. Este passo é usado com a intenção de dividir a imagem em partes que permitam a identificação de regiões, que sejam candidatas a tecido doente. Para unir as diversas regiões, separando o fundo da possível lesão, aplica-se um método de união que leva em consideração a coloração do tecido saudável.

Após a execução destes passos, obtém-se uma imagem binarizada. Usando os conceitos de vizinhança e distância *chessboard*, define-se um vetor com os pontos que formam um caminho próximo à borda da lesão. Desta forma, obtém-se uma curva inicial para ser usada como marcador pelo método de *watershed*. As curvas (bordas) retornadas por este método são processadas pelo modelo de contorno ativo, ajustando então o contorno sobre a lesão. No último estágio do método, caracterizam-se as bordas, extraindo informações sobre rugosidade, simetria e diâmetro das lesões.

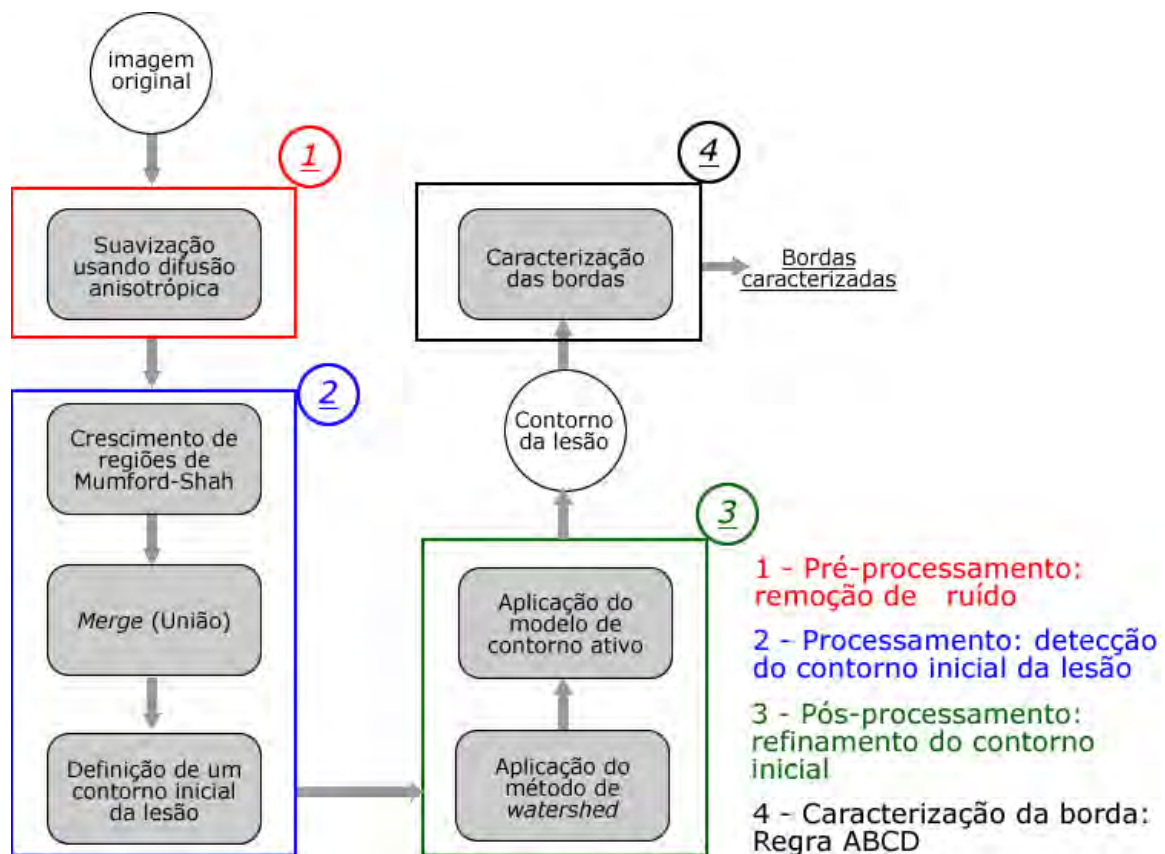


Figura 3.1: Diagrama de fluxo geral do método proposto.

Nas seções seguintes, cada passo do método desenvolvido é descrito com os detalhes de suas características e implementação.

3.1 Suavização

A suavização seletiva proporcionada pela difusão anisotrópica, foi o principal motivo pelo qual esta abordagem foi escolhida para remoção de ruídos na imagem. No entanto, um número excessivo de iterações da equação de difusão sobre a imagem, pode provocar perda de informações referentes à borda. Isto ocorre porque tanto as bordas quanto os ruídos possuem características semelhantes (por exemplo, ambos estão relacionados às altas frequências na imagem). Assim, se a difusão for aplicada em excesso, os detalhes de rugosidade da borda, bem como as pequenas lesões, passam a ser interpretados como ruídos e são eliminados.

Portanto, a definição do número de iterações depende de cada imagem e está relacionado à sua quantidade de ruídos. No método de segmentação desenvolvido, não é necessário eliminar completamente o ruído da imagem por dois motivos. Primeiro porque

a versão suavizada da imagem é inicialmente usada para obter um contorno aproximado da lesão. O segundo motivo é que, desde que não seja em excesso, o método de crescimento de regiões consegue manipular imagens com diferentes quantidades de ruído. Desta forma, é suficiente que parte do ruído seja eliminado, podendo usar uma aproximação para o número de iterações do modelo de difusão anisotrópica. Com isso, antes de aplicar a suavização define-se um número aproximado de iterações automaticamente, a partir da relação entre os operadores de gradiente de Roberts e Prewitt, como pode-se observar no diagrama de fluxo da figura 3.2.

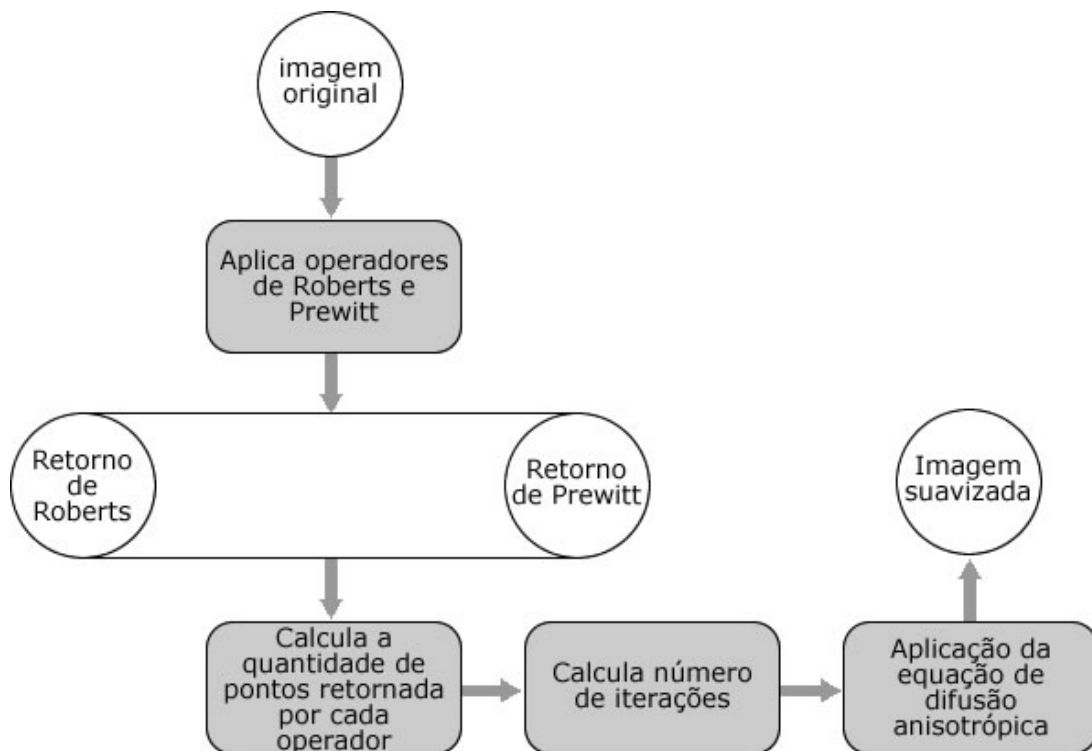


Figura 3.2: Diagrama de fluxo da etapa de suavização.

3.1.1 Estimativa automática do número de iterações da difusão anisotrópica

Na tentativa de automatizar o método de suavização usando difusão anisotrópica, propõe-se a utilização de dois operadores de gradiente, e a partir da diferença de bordas retornadas por estes, define-se o número a usar de iterações do método de remoção de ruídos.

Os operadores usados foram o de Prewitt e de Roberts. Esta escolha ocorreu devido à diferença de comportamento dos dois filtros diante da presença de ruídos. Como se pode observar na figura 3.3, o operador de Roberts retorna mais arestas falsas (pontos e linhas em branco) quando comparado com o de Prewitt. Um dos motivos desta diferença é a

suavização que ocorre quando se aplica a máscara de Prewitt. Assim, a partir desta diferença foi possível fazer uma estimativa do número de iterações da suavização por difusão anisotrópica, suficiente para obter o processamento nos passos seguintes do algoritmo.




Figura 3.3: Aplicação dos operadores de Prewitt em (b) e de Roberts (c) numa imagem ruidosa (a).

Diante de testes realizados, foi possível perceber que quanto maior for a interferência de ruídos na imagem original, maior é a diferença de pontos detectados pelos operadores de Prewitt e de Roberts, como se pode verificar na figura 3.4. Nesta figura, apresenta-se o gráfico da quantidade de pontos retornados pela aplicação dos dois operadores sobre as imagens (a), (b), (c) e (d) da mesma figura. Pode-se observar pelo gráfico, que a diferença entre a quantidade de pixels obtidos pelos operadores, aumenta à medida que estes são aplicados em cenas mais ruidosas.

Como consequência desse aumento, pode-se concluir que quanto maior for a diferença entre os operadores, mais iterações (n) da difusão deve-se aplicar na imagem original para amenizar a interferência de ruídos. Diante disso, propõe-se uma estimativa para n baseada na diferença de pontos retornados pelos dois operadores:

$$n = \frac{[N_R(I) - N_P(I)][P_R - P_P]}{100}, \quad (3.1)$$

$$P_R = \frac{100N_R}{rc},$$

$$P_P = \frac{100N_P}{rc},$$

onde:

- I é a imagem original;

- rc é o número total de pixels de I ;
- N_P é o número de pixels retornados pelo operador de Prewitt;
- N_R é o número de pixels retornados pelo operador de Roberts;
- P_P é a porcentagem que N_P representa em relação a rc ;
- P_R é a porcentagem que N_R representa em relação a rc ;

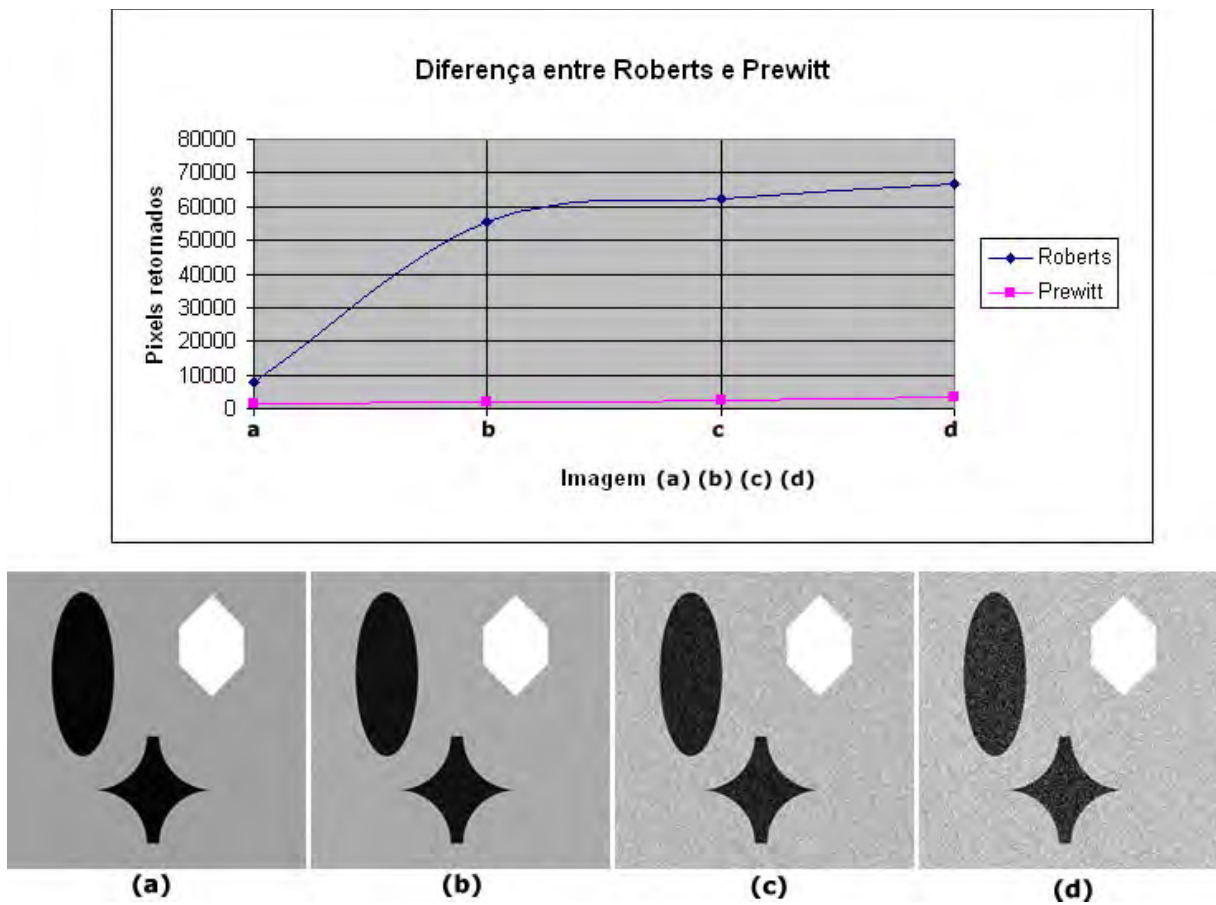


Figura 3.4: Gráfico da evolução do número de pontos retornados pela aplicação dos operadores de Roberts e de Prewitt nas imagens apresentadas em baixo (a-d) com diferentes quantidades de ruído.

Com a equação 3.1, quanto maior a diferença entre os dois operadores (e, consequentemente mais ruídos presentes na imagem), maior é o número de iterações retornado, como vê-se no gráfico da figura 3.5, obtido pela aplicação da equação 3.1 nas imagens da figura 3.4.




Figura 3.5: Gráfico da evolução das iterações calculadas pelo método proposto nas imagens da figura 3.4.

3.1.2 Aplicação da difusão anisotrópica

Após definir o número de iterações da difusão anisotrópica para suavização da imagem, aplica-se o modelo da equação 2.56, proposto por Barcelos e colaboradores [3] utilizando:

- $\Delta t = 0.1$;
- $g = \frac{1}{1 + k|G_\sigma u^t|^2}$;
- k é um valor constante;
- u^t é a imagem suavizada no passo t ;
- $G_\sigma(x, y) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2+y^2}{2\sigma^2}}$;
- σ é usado para definir o desvio padrão da função gaussiana, e foi adotado neste trabalho como sendo constante, com valor 1.

Vale ressaltar que aplicou-se a difusão em imagens coloridas. Portanto, suavizou-se cada componente de cor da imagem.

3.2 Crescimento de regiões

As imagens com muito ruído prejudicam o processo de crescimento de região. Nestes casos, as imagens retornadas são compostas por regiões muito pequenas e o ruído acaba sendo evidenciado ou inserido, principalmente onde ocorre a transição entre as regiões. Como pode-se observar na figura 3.6, próximo às bordas das regiões em (b) e (d), surgiram pequenas áreas pretas que não estavam presentes nas imagens originais (a) e (c), dificultando a extração de bordas. Por isso, aplicou-se o filtro para suavização usando difusão anisotrópica antes do crescimento de regiões.




Figura 3.6: Resultado da aplicação de crescimento de região ((b) e (d)) em imagens sem suavizar ((a) e (c)).

Após a suavização, aplica-se o método de crescimento de regiões para efetuar a segmentação da imagem, agrupando as partes semelhantes em regiões maiores. Com isso, a imagem de entrada (imagem suavizada) fica representada por um conjunto de regiões homogêneas, facilitando a definição das partes da pele que formam a possível região doente.

Existem várias abordagens para o crescimento de regiões propostas na literatura [35], [41], [10]. Uma muito usada é a *quadtree*, que usa os conceitos de árvore quaternária [18],

dividindo recursivamente cada região da imagem (chamada de quadrante), até que a intensidade de todos os pixels do quadrante pertençam a um intervalo definido pelos limiares adotados.

Usando, por exemplo, como limiares, a média m da intensidade dos pixels do quadrante com uma variação de 25%, tem-se $T_1 = 0.75m$ e $T_2 = 1.25m$. Portanto, tem-se o intervalo de intensidades aceitável (ou parâmetro de crescimento) para uma dada região R definido por $[T_1, T_2]$, onde T_1 e T_2 são os limiares. Desta forma, se todos os pixels do quadrante analisado possuem intensidade pertencente a este intervalo, todo o quadrante passa a ter a intensidade de cor m . Caso contrário, o quadrante é dividido em 4 regiões de mesmo tamanho, até que a condição definida pelo parâmetro de crescimento seja atendida. Na figura 3.7 tem-se um exemplo da aplicação deste método nas imagens (a) e (c), suavizadas através da difusão anisotrópica.




Figura 3.7: Resultado da aplicação de crescimento de região *quadtree* ((b) e (d)) nas imagens suavizadas (a) e (c).

As imagens resultantes da aplicação do método de crescimento de região *quadtree* estão em (b) e (d), respectivamente. Pode-se observar que este método provocou perda no contraste entre a lesão e o fundo, principalmente nas áreas marcadas pelas elipses

amarelas. Com isso, o crescimento de regiões por *quadtree* não foi interessante para os objetivos deste trabalho. É importante ressaltar que o método é aplicado em cada canal de cor RGB separadamente, juntando posteriormente as matrizes retornadas em cada etapa para formar a imagem colorida final.

Na tentativa de obter resultados mais precisos, onde a diferença entre todas as regiões fosse aumentada, aplicou-se o método de crescimento de regiões baseado no funcional de Mumford-Shah. Apesar de ser um método computacionalmente complexo e com tempo de execução elevado, este é menos sensível a variações na imagem, e é comumente utilizado por retornar resultados mais precisos do que as outras abordagens de crescimento de região.

Esta abordagem foi inicialmente proposta para imagens em níveis de cinza. Diante disso, a primeira tentativa foi converter a imagem do sistema de cores RGB para o HSV, e aplicar este método na componente intensidade. A componente intensidade foi escolhida porque ela possui mais informações sobre as lesões nas imagens analisadas, como pode-se observar na figura 3.8. Nesta figura, as componentes matiz (H), saturação (S) e intensidade (V) são mostradas em (b), (c) e (d), respectivamente.




Figura 3.8: Imagem original (a) e suas componentes HSV, que são mostradas em (b) matiz, (c) saturação e (d) intensidade, respectivamente.

Na figura 3.9 tem-se o resultado da aplicação do método de crescimento de região na componente V (intensidade) do modelo de cores HSV. Percebe-se que houve perda de detalhes das lesões nas regiões marcadas pelas elipses amarelas. No resultado da aplicação na primeira imagem (b), um pedaço da parte de cima da lesão se misturou com o fundo, enquanto outro pedaço pertencente ao fundo ficou conectado com a área doente na parte inferior. Em (d) (resultado do processamento da segunda imagem (c)), uma área doente na parte inferior da lesão não foi detectada.




Figura 3.9: Aplicação do crescimento de região na componente intensidade. (a) e (c) são as imagens originais suavizadas e (b) e (d) o resultado do crescimento de região.

Devido à perda de informação referente à forma da lesão, provocada pela aplicação do crescimento de região na componente intensidade do sistema de cores HSV, aplicou-se o crescimento de regiões nas três componentes do sistema de cor RGB, usando as matrizes resultantes para montar a imagem de saída. Desta forma, o contraste entre as regiões da lesão é aumentado, como observa-se na figura 3.10. Além disso, as áreas destacadas pelas elipses amarelas nas imagens (b) e (d) ficaram com bom contraste em relação ao fundo, o que não aconteceu quando se aplicou o crescimento de regiões de Mumford-Shah apenas sobre a componente intensidade.




Figura 3.10: Aplicação do crescimento de região de Mumford-Shah na imagem RGB. (a) e (c) são as imagens originais suavizadas e (b) e (d) o resultado do crescimento de região.

Analisando os resultados destas abordagens de crescimento de regiões, constatou-se que esta última apresentou melhores resultados. Assim, a etapa de crescimento de regiões do método de segmentação proposto pode ser descrita graficamente pelo diagrama de fluxo da figura 3.11. Neste etapa, a imagem suavizada é dividida em três matrizes, sendo uma para cada componente de cor do sistema de cores RGB. Em seguida aplica-se o método de Mumford-Shah em cada componente e unem-se as três matrizes resultantes, formando uma imagem colorida na saída.

O método de crescimento de regiões visa agrupar pixels semelhantes, dividindo a imagem no menor número de regiões possível. Testou-se a aplicação do método de quantização de cores, por corte mediano antes da etapa de crescimento de regiões, com o objetivo de reduzir o espaço de cores da imagem original. No entanto, após os testes a etapa de quantização foi descartada, porque o resultado em imagens com a presença de uma quantidade maior de ruído foi inferior ao processamento sem sua aplicação.

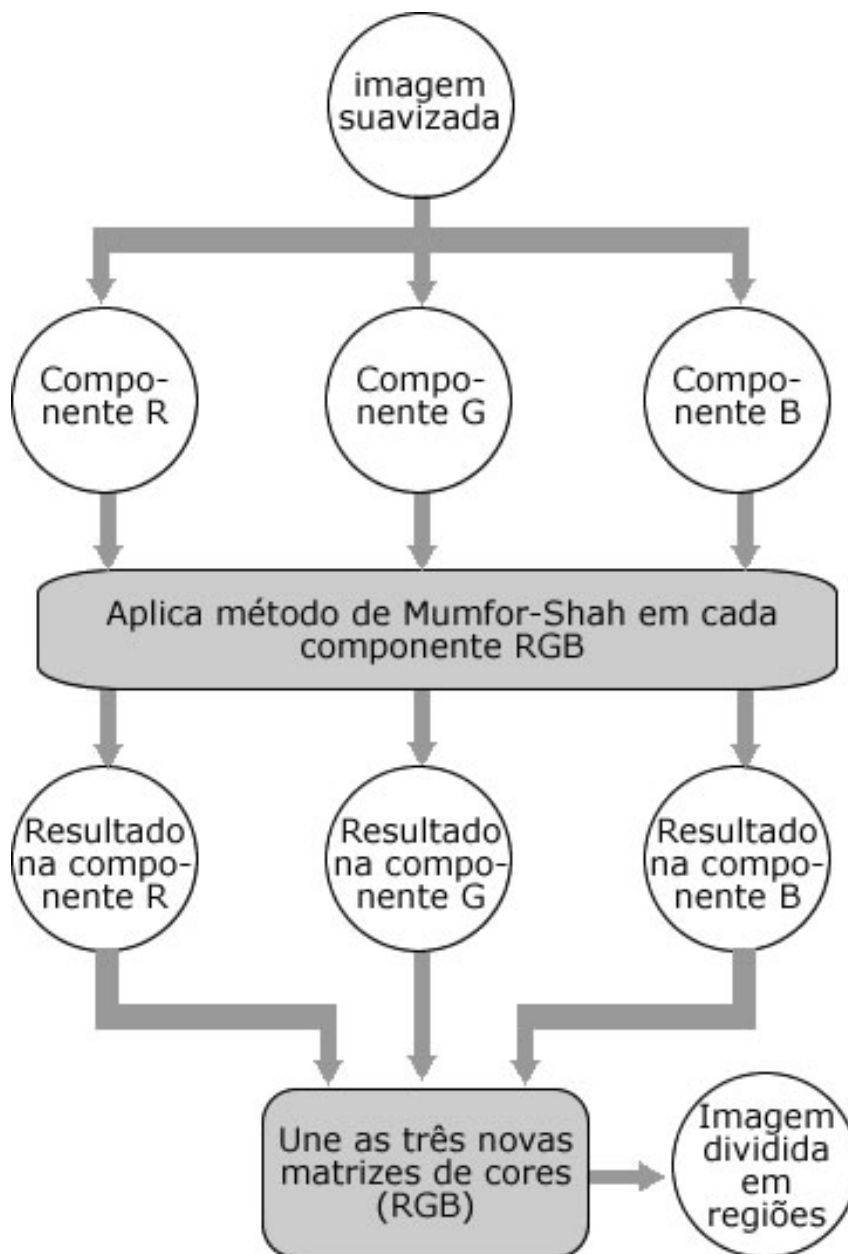


Figura 3.11: Diagrama de fluxo da etapa de crescimento de região.

Na figura 3.12, tem-se o resultado da divisão de duas imagens, onde se aplicou a quantização antes da etapa de suavização. Pode-se observar que o resultado não foi bom, principalmente na imagem (d), onde as áreas destacadas em amarelo sofreram perda significativa de contraste. Portanto, o uso da quantização de cores neste trabalho foi descartado.




Figura 3.12: Resultado do crescimento de região na imagem RGB quantizada. (a) e (c) são as imagens suavizadas após a quantização e (b) e (d) o resultado do crescimento de região.

3.3 Merge (*União*)

Após aplicar o crescimento de regiões na imagem, as partes que formam o tecido saudável tendem a se diferenciar das partes doentes em relação à cor. Como pode-se observar na figura 3.13, a maioria das regiões que não estão doentes possuem cores diferentes das partes que formam as lesões. Nota-se também que há algumas áreas separadas, mas que possuem cores semelhantes, como por exemplo, as regiões marcadas por elipses na imagem (b). A divisão da imagem em regiões de cores, ajuda aumentar a diferença de cor entre as partes doentes e saudáveis. No entanto, para determinar quais regiões são lesões, deve-se binarizar a imagem, transformando as regiões doentes em um nível de cor e as saudáveis em outro. Para tal, pode-se usar técnicas de binarização a partir de algoritmos de *merge* (união).




Figura 3.13: Imagens após crescimento de região.

Foram usadas duas abordagens para fazer a união das regiões doentes. A primeira considera a intensidade de cor de uma região saudável como parâmetro de união. Assim, as regiões cuja intensidade for muito diferente, em relação ao parâmetro de união, é considerada pertencente à lesão. Esta abordagem gera bons resultados, mas exige a indicação de uma região saudável. Como um dos objetivos deste trabalho é extrair automaticamente as bordas da área doente, esta abordagem foi adaptada para funcionar sem intervenção humana, como descrito a seguir.

Após análise das imagens processadas neste trabalho, percebeu-se que as lesões estão geralmente afastadas dos cantos da imagem. Uma solução encontrada para efetuar o *merge* automaticamente, usando a intensidade da cor da região saudável como parâmetro de união, foi considerar que os cantos da imagem são formados por tecido saudável. Desta forma, calcula-se a média da intensidade de um conjunto de pixels em cada canto da imagem, tomando-a como parâmetro. Na figura 3.14 (b) tem-se o resultado da binarização de uma imagem dividida em regiões (figura 3.14 (a)). Esta binarização foi realizada usando esta primeira abordagem do método de união. Comparando a imagem binarizada (b) com sua respectiva original (c), nota-se que o resultado foi satisfatório, pois permite a extração de um contorno aproximado e que possui a topologia da lesão. Além disso, este contorno é suficiente para ser usado na etapa seguinte (pós-processamento) do método de segmentação desenvolvido.

Entretanto, este método de união pode falhar para imagens que possuam alguma região doente nos cantos. Neste caso, o parâmetro de união pode ficar próximo do valor da intensidade de algumas áreas doentes, passando a ser um limiar inadequado. Assim, estas regiões podem ser consideradas, equivocadamente, como regiões saudáveis.




Figura 3.14: (a) imagem após crescimento de regiões, (b) imagem binarizada com *merge* usando a média de intensidade dos cantos e (c) a imagem original.

Para solucionar este problema, foi elaborada uma segunda abordagem para o método *merge*. Na figura 3.15, tem-se três regiões numeradas de 1 a 3 e, na tabela 3.1 tem-se o valor das componentes RGB para cada uma das três regiões. As regiões 1 e 2 pertencem à área doente, enquanto a região 3 é saudável. Observando-se a imagem da figura 3.15, percebe-se que há uma diferença significativa de cor entre as regiões doentes e saudáveis. Assim, esta segunda abordagem utiliza a distância entre as cores como parâmetro de união.

Tabela 3.1: Tabela de cores RGB das regiões 1, 2 e 3 da figura 3.15.

Região	R	G	B
1	37	36	35
2	102	36	35
3	155	124	106




Figura 3.15: Imagem após aplicação do método de crescimento de regiões.

Na tabela 3.2 tem-se as distâncias entre as cores das três regiões numeradas da figura 3.15. Nota-se que as distâncias entre as regiões 1 e 3 ($D_{1,3}$) e 2 e 3 ($D_{2,3}$) são muito maiores do que $D_{1,2}$. Desta forma, dividindo as regiões entre as classes saudável e doente, concluiu-se após testes realizados neste trabalho, que as distâncias entre as cores de regiões de classes diferentes são maiores do que entre as áreas de mesmas classe. Assim, o algoritmo de união desenvolvido neste trabalho é apresentado no diagrama de fluxo da figura 3.16.

Tabela 3.2: Distâncias entre as cores das regiões 1, 2 e 3 da figura 3.15.

Regiões	Distância
1 e 2	65
1 e 3	163,43
2 e 3	124,88

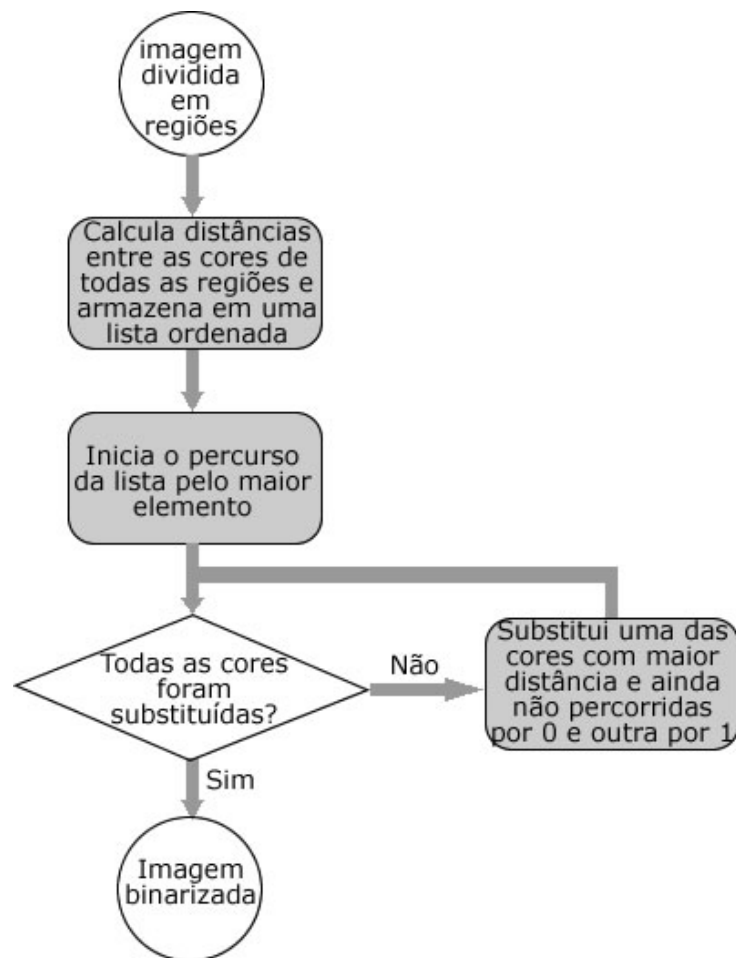


Figura 3.16: Diagrama de fluxo da etapa de *merge*.

Esta etapa recebe a imagem dividida em regiões pelo método de Mumford-Shah e

calcula a distância entre as cores de todas as regiões. A cada par de cores (c_1 e c_2) analisado, cria-se um nó em uma lista ordenada pelo valor da distância entre as cores, armazenando c_1 e c_2 e sua respectiva distância, tomando o cuidado de não inserir pares de cores repetidos. Em seguida, percorre-se a lista começando pelo elemento de maior distância, substituindo c_1 por 0(zero) e c_2 por 1(um) na imagem de entrada desta etapa, até que todas as cores das regiões sejam substituídas, retornando uma imagem binarizada. Na figura 3.17 têm-se alguns exemplos de imagens binarizadas por esta abordagem do método *merge*. Nota-se que o método foi capaz de isolar as regiões doentes do restante da imagem. As imagens binarizadas são usadas para extrair os contornos iniciais das lesões na etapa seguinte do método desenvolvido.




Figura 3.17: Imagens binarizadas pelo método *merge* usando a distância entre as cores das regiões como parâmetro de união.

3.4 Definição do contorno inicial da lesão

Com a imagem binarizada pode-se definir um contorno inicial da lesão para ser usado na etapa de pós-processamento do método desenvolvido neste trabalho. O contorno inicial é resultante da busca pixel a pixel pelas alterações abruptas na imagem binarizada. O pós-processamento é aplicado para refinar o resultado da segmentação realizada nas etapas anteriores. Na figura 3.18, por exemplo, pode-se observar os contornos de duas lesões. Em ambas imagens as bordas foram resultantes da aplicação das etapas já descritas, do método desenvolvido neste trabalho. Em (a) o contorno inicial envolve corretamente a região doente, mas na imagem (b) tem-se algumas regiões da lesão (marcadas em amarelo) que não foram detectadas.




Figura 3.18: Contorno inicial sobreposto às lesões. O contorno encontra-se na cor branca.

Foram adotadas duas técnicas para fazer o pós-processamento: contorno ativo e *watershed*. Para o modelo de contorno ativo usou-se a borda resultante da imagem binarizada. Desta forma, a curva inicial usada pelo algoritmo de contorno ativo já possui a topologia da lesão.

Para a abordagem do algoritmo de *watershed* adotado, os contornos iniciais usados como marcadores também foram obtidos a partir da borda inicial. Para garantir que um desses contornos iniciais seja interno à lesão e o outro externo, o contorno inicial é duplicado e uma cópia aumentada em 15 pixels em cada direção (direita, esquerda, para cima e para baixo), enquanto a outra é reduzida em 15 pixels em cada direção. Na figura 3.19 tem-se em (a) um exemplo da curva inicial para o modelo de contorno ativo e, em (b) os marcadores usados pela abordagem de *watershed* adotada. Ambos os métodos de pós-processamento (contorno ativo e *watershed*) são descritos nas seções seguintes.




Figura 3.19: Em (a) tem-se a curva inicial usada pelo modelo de contorno ativo e em (b) os marcadores para o método *watershed*.

3.5 Pós-processamento do contorno inicial

Nesta seção descreve-se como foi desenvolvida a etapa de pós-processamento deste trabalho. Esta etapa foi dividida em dois passos: primeiro, aplicando-se um método de crescimento de regiões baseado em *watershed*, e segundo, usando um modelo de contorno ativo. Ambos foram usados para fazer o refinamento da borda, ajustando-a à lesão e evidenciando suas características de irregularidade.

3.5.1 Aplicação do método de *watershed*

Como se observa na imagem (b) da figura 3.19, o contorno inicial, extraído após a aplicação do crescimento de regiões de Mumford-Shah e do método *merge*, não envolve todas as áreas doentes. Para aumentar a precisão do contorno, foi desenvolvida uma etapa de pós-processamento usando um método de crescimento de regiões morfológico, o *watershed*. Para evitar a ocorrência de super-segmentação, e também aproveitando o fato de ter sido extraído um contorno inicial para a lesão, aplicou-se o algoritmo de *watershed* descrito por Meyer em [31] e implementado pela biblioteca de manipulação de imagens *OpenCV* [37].

Este método utiliza uma máscara contendo os marcadores iniciais, a partir de onde o fluxo de água iniciará a inundação das bacias. Além da imagem já suavizada, este método recebe uma máscara com um esboço das regiões que se deseja separar. Assim, no método desenvolvido, esta máscara é formada pelo contorno inicial alargado e contraído, obtido

na etapa anterior. As curvas marcadas na máscara definem as posições dos pontos de mínimo a serem considerados durante o processo de inundação.

Na figura 3.20, têm-se, nas imagens (a) e (c), os contornos iniciais, onde as curvas na cor branca são usadas como marcadores para o processo de inundação. O resultado da aplicação nestas imagens do algoritmo de *watershed* adotado pode ser visto nas imagens (b) e (d), respectivamente. Percebe-se que o contorno inicial foi ajustado à lesão, envolvendo toda a região doente.




Figura 3.20: Aplicação do método de *watershed* adotado. Em (a) e (c) têm-se os contornos iniciais usados como marcadores e em (b) e (d) os resultados da aplicação do método.

3.5.2 Aplicação do modelo de contorno ativo

Outra técnica usada para pós-processar as imagens neste trabalho foi o modelo de contorno ativo. Assim como o *watershed*, usou-se o contorno ativo para refinar a borda resultante da aplicação dos métodos de crescimento de regiões e *merge*.

Foram utilizados dois modelos de contorno ativo neste trabalho: o modelo tradicional [27] e o modelo GVF [52]. Em ambos, foram adotados parâmetros constantes e de forma que o salto do contorno inicial, em cada iteração, fosse pequeno. Na tabela 3.3, têm-se os parâmetros adotados para os modelos. Os parâmetros de elasticidade e rigidez da equação 2.21 (α e β , respectivamente) foram definidos com valores baixos para evitar suavização excessiva da borda. Além disso, o peso da força externa também foi baixo para evitar saltos muito grandes entre uma iteração e outra. Evitando assim que o limite da lesão não seja detectado.

Tabela 3.3: Parâmetros usados nos modelos de contorno ativo.

Modelo	Elasticidade	Rigidez	Peso da força externa	Iterações
Tradicional	0,05	0,05	0,1	150
GVF	0,05	0,05	0,1	75

Na figura 3.21 pode-se ver o resultado da aplicação dos modelos de contorno ativo adotados. Na imagem (a) tem-se a curva inicial, retornada a partir da imagem binarizada pelo método *merge*. Em (b) esta curva é sobreposta à imagem original, em (c) o contorno é retornado pelo modelo tradicional, e em (d) pelo método GVF. Nota-se, no exemplo desta figura, que a deformação da curva inicial, em relação ao seu tamanho e posicionamento, foi mínima devido aos parâmetros adotados. Neste trabalho, optou-se por usar esta abordagem, em decorrência do fato da curva inicial ser próxima do contorno final das lesões. Assim, o contorno ativo foi usado para refinar as bordas, ajustando-as às lesões e envolvendo as regiões doentes, que ainda não tenham sido envolvidas, ou eliminando áreas saudáveis que foram capturadas, como pode-se observar nas áreas marcadas em amarelo na figura 3.21.




Figura 3.21: Exemplo dos modelos de contorno ativo tradicional (c) e GVF (d), aplicados sobre a curva (a). Em (b) tem-se a curva (a) sobreposta à imagem.

O uso destes modelos de contorno ativo, com as características adotadas neste trabalho, necessita de uma curva inicial próximo do contorno desejado. Caso o contorno inicial seja muito diferente do desejado, o número de iterações deve ser aumentado e, consequentemente, pode acontecer uma suavização excessiva de partes da borda. Desta forma, na tentativa de obter bordas mais aceitáveis, preservando melhor as características de rugosidade, dividiu-se a etapa de pós-processamento em dois passos. No primeiro aplicou-se o método de *watershed*, como descrito na seção anterior. No segundo passo, aplicaram-se estes mesmos modelos de contorno ativo. No entanto, a curva inicial adotada foi a resultante da aplicação do método de *watershed*.

Na figura 3.22, tem-se em (a) a imagem original. As imagens (b) e (c) são, respectivamente, os resultados dos modelos de contorno ativo tradicional e GVF, aplicados sobre a curva obtida pelos métodos de crescimento de regiões e *merge*. Em (d) e (e) têm-se, respectivamente, as bordas após a aplicação dos contornos ativos tradicional e GVF sobre a

curva (borda) resultante do método de *watershed*. Pode-se observar que a borda ilustrada na figura 3.22 (d) apresenta melhor encaixe sobre a lesão e definição da rugosidade. O resultado do GVF apresentado em (e) gerou um fechamento excessivo na parte marcada em amarelo.




Figura 3.22: Exemplo dos modelos de contorno ativo tradicional (b) e (d) e GVF (c) e (e) aplicados usando curvas iniciais diferentes. Em (a) tem-se a imagem original.

Este melhor comportamento do modelo tradicional, aplicado sobre o resultado do *watershed*, foi observado também nos testes realizados sobre as demais imagens, como pode ser visto com mais detalhes no capítulo seguinte. Assim, a etapa de pós-processamento do método desenvolvido neste trabalho é apresentada no diagrama de fluxo da figura 3.23.

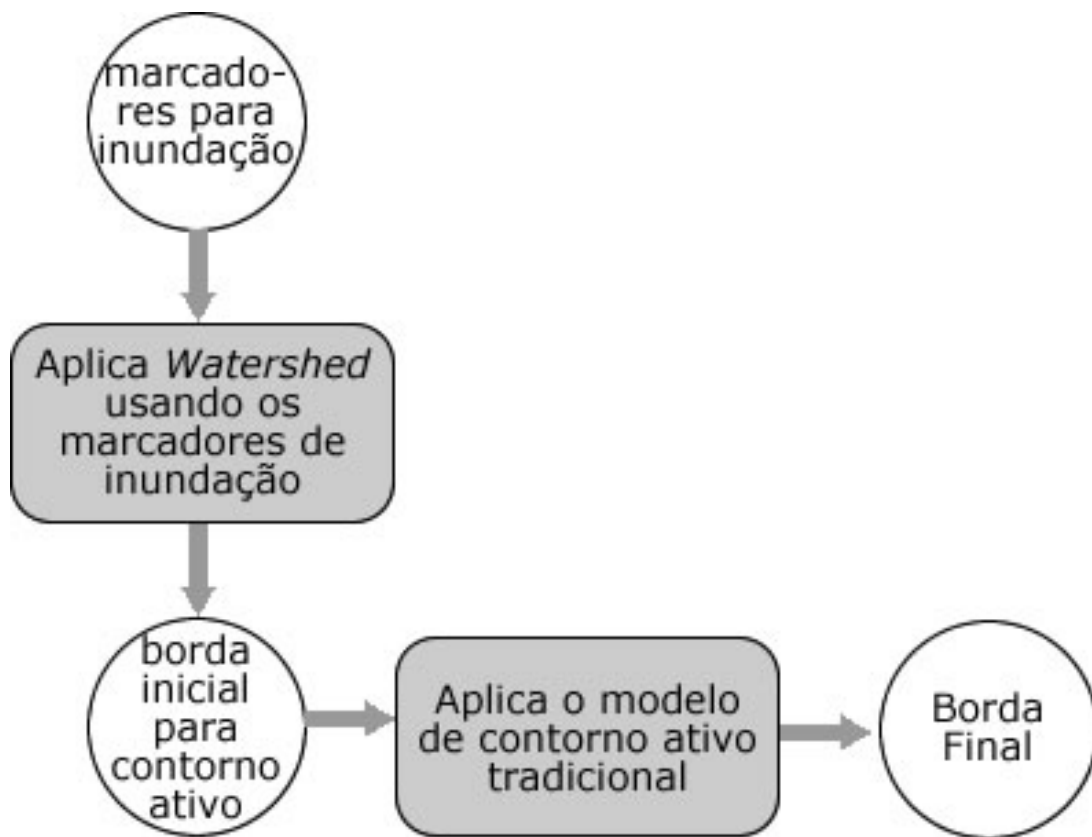


Figura 3.23: Diagrama de fluxo da etapa de pós-processamento.

Esta é a última etapa de manipulação da borda. A partir deste passo, o contorno é apenas analisado, sendo usado para definir as características das lesões. O pós-processamento inicia-se com a aplicação do método de *watershed*, utilizando os marcadores determinados na etapa de definição do contorno inicial. O resultado deste método é usado como curva inicial para deformação através do modelo de contorno ativo tradicional, sendo obtido o contorno final que envolve as regiões doentes. Na seção seguinte descreve-se como foi feita a caracterização das lesões a partir dos resultados desta etapa.

3.6 Caracterização das bordas

Este trabalho tem como foco a detecção automática de lesões cancerosas em imagens de pele, e a extração de suas características de acordo com a regra ABCD. Desta forma, as características extraídas pelo método desenvolvido, devem auxiliar o dermatologista na definição da assimetria, da irregularidade da borda, da variação da coloração interna e do diâmetro das lesões. Como apresentado no capítulo 2, estas características são importantes por possibilitarem um diagnóstico inicial do tipo das lesões.

A etapa de caracterização desenvolvida neste trabalho, pode ser descrita de acordo com o diagrama de fluxo da figura 3.24. Nesta etapa, a borda da lesão detectada e extraída pelas etapas anteriores é processada, calculando-se primeiramente o seu diâmetro (maior diagonal). Em seguida, definem-se a assimetria, a irregularidade da borda e a variação da cor interna. Na figura 3.24 apresenta-se cada passo desta etapa mais detalhadamente, discutidos nas próximas seções.

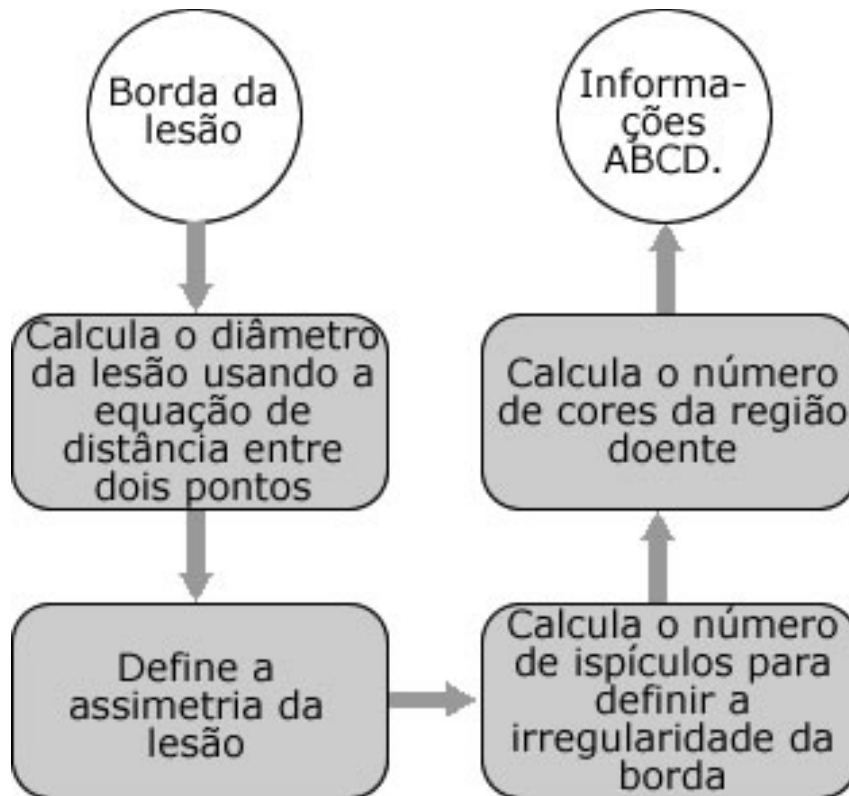


Figura 3.24: Diagrama de fluxo da etapa de caracterização.

3.6.1 Cálculo do diâmetro (D)

Para calcular o diâmetro da lesão, usou-se a equação 3.2 para cálculo da distância euclidiana entre dois pontos.

$$D_{(p,q)} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}, \quad (3.2)$$

onde p e q são dois pontos, cujas coordenadas são (x_1, y_1) e (x_2, y_2) , respectivamente.

O diâmetro de uma lesão é definido pela maior distância entre dois pontos de sua borda, ou seja, a maior diagonal que liga dois pontos de borda da região doente. Assim, neste trabalho calculam-se as distâncias entre todos os pares de pontos pertencentes ao contorno da lesão, retornando a maior delas como diâmetro. Na figura 3.25, têm-se dois

exemplos das maiores diagonais calculadas a partir das bordas das lesões das imagens (a) e (b).




Figura 3.25: Exemplos da maior diagonal (em vermelho), calculada pelo método de caracterização.

As curvas na cor branca são os contornos extraídos pelas etapas anteriores, e as linhas em vermelho são as diagonais maiores, cujo comprimento é o diâmetro das lesões. O primeiro passo da etapa de caracterização foi o cálculo da diagonal maior, devido à importância desta para a definição da assimetria.

3.6.2 Definição da assimetria (A)

Para definição automática da assimetria, propôs-se a divisão das lesões em três classes: simétrica, levemente assimétrica e acentuadamente assimétrica. A classificação das lesões foi feita a partir da análise das semi-retas perpendiculares à diagonal maior. Primeiramente são definidas todas as linhas que ligam os pontos do contorno, cruzando a diagonal maior, e que sejam perpendiculares a esta. Em seguida, divide-se cada linha no ponto de interseção com a diagonal maior, obtendo duas novas linhas, uma de cada lado da diagonal maior, como ilustrado na figura 3.26, pelas linhas ($L1$) na cor rosa, e ($L2$) em amarelo.




Figura 3.26: Exemplo de comparação de uma linha perpendicular à diagonal maior, usada para definição da assimetria.

Após a divisão da linha perpendicular à diagonal maior, calcula-se a diferença de tamanho entre os seus segmentos ($L1$) e ($L2$), definindo a porcentagem desta diferença em relação ao maior dos segmentos. Assim, a diferença fica definida em função do maior lado da linha perpendicular. Este cálculo é feito para todas as perpendiculares.

Para definir à qual classe de assimetria a lesão pertence, definiram-se dois limiares T_1 e T_2 , usados para dividir o conjunto de perpendiculares em três grupos:

- **Grupo1:** as perpendiculares cuja diferença for menor ou igual a T_1 ,
- **Grupo2:** as perpendiculares cuja diferença for maior do que T_1 e menor ou igual a T_2 e,
- **Grupo3:** as perpendiculares cuja diferença for maior do que T_2 .

Com o objetivo de definir estes limiares de forma que pudessem ser usados para todas as imagens processadas, analisou-se, a partir do uso de histogramas, a distribuição das diferenças entre os segmentos $L1$ e $L2$ das retas perpendiculares à diagonal maior. Na figura 3.27, tem-se o exemplo de duas lesões e seus respectivos histogramas. A imagem (a) é de uma lesão simétrica, e a (b) de uma assimétrica.




Figura 3.27: Exemplo de histogramas das diferenças das perpendiculares de uma lesão simétrica (a) e assimétrica (b).

Usando os histogramas de um conjunto de 10 imagens variadas, com assimetria previamente definida através de análise visual, percebeu-se que ocorreu uma maior concentração entre os valores 0(zero) e 30 para as bordas simétricas, e acima de 45 para as acentuadamente assimétricas. Assim, adotou-se neste trabalho, $T_1 = 30$ e $T_2 = 45$.

Com estes limiares definidos as lesões foram classificadas a partir da análise de seus histogramas, dividindo-as em classes da seguinte forma:

- **simétrica:** se o Grupo1 contiver mais elementos do que os demais,
- **levemente assimétrica:** se o Grupo2 for maior que os demais e,
- **acentuadamente assimétrica:** se o Grupo3 contiver mais elementos.

3.6.3 Cálculo da quantidade de ispículos (B)

Para definir a irregularidade das bordas, desenvolveu-se neste trabalho, uma abordagem baseada nos pontos de inflexão. Estes pontos são aqueles em que as curvas mudam de côncavas para convexas, ou vice-versa. Para encontrar estes pontos em que as bordas mudam de direção, desenvolveu-se duas técnicas. A primeira retira a assinatura da borda, e através desta procura os pontos em que ocorrem mudanças de direção, definindo seus pontos de inflexões (picos e vales). A segunda técnica percorre a assinatura da borda, calculando o produto vetorial entre dois vetores definidos por pontos pertencentes a esta.

Para a primeira técnica percorre-se todos os pontos p_i da assinatura da borda, analisando os quatro vizinhos do lado esquerdo e os quatro do lado direito de p_i . Na figura 3.28, tem-se o esquema de um ponto de inflexão na cor vermelha, e seus quatro vizinhos à esquerda (na cor azul) e à direita (na cor verde).




Figura 3.28: Exemplo de um ponto de inflexão (vermelho) e seus vizinhos direitos (verde) e esquerdos (azul).

Para determinar se o ponto p_i é uma inflexão, definiram-se pesos para cada um dos oito vizinhos de p_i (os quatro da direita e os quatro da esquerda) da seguinte forma:

- se o vizinho estiver abaixo de p_i em relação à coordenada y , ele recebe peso 1 e,
- se estiver acima de p_i em relação à coordenada y , ele recebe peso -1.

Se a soma dos pesos for superior ou igual a 2, ou inferior ou igual a -2, para ambos os lados, considerou-se a existência de uma inflexão. Caso seja detectada uma mudança de direção e a soma dos pesos seja positiva, a inflexão é um pico, caso seja negativa é um vale. Assim, cada ponto de inflexão está associado a uma oscilação da borda, como pode-se observar na figura 3.29. Nesta figura, é apresentado um trecho da assinatura de um contorno (imagem (a)), onde a região em vermelho pertence ao interior da borda, e as marcações em azul e branco são as inflexões. Neste caso, as marcas na cor branca são os picos e em azul os vales, como pode-se observar com mais detalhes na imagem (b), que é ampliação da região marcada na cor amarela em (a).




Figura 3.29: Trecho da assinatura de uma borda, com as inflexões marcadas em azul e branco.

Cada ispículo é formado por um pico cercado por um vale à direita e outro à esquerda. Como este método faz uma análise apenas dos vizinhos próximos de p_i , ele retorna as pequenas variações da borda, dificultando a detecção dos ispículos maiores.

Na tentativa de obter um método para definição dos ispículos maiores, desenvolveu-se neste trabalho uma segunda técnica para calcular as inflexões, baseando-se no produto vetorial. Considerando três pontos $p_1 = (x_1, y_1)$, $p_2 = (x_2, y_2)$ e $p_3 = (x_3, y_3)$ pertencentes à borda da lesão, pode-se definir o direcionamento da curva formada pelos pontos $(\widehat{p_1 p_2 p_3})$, a partir do produto vetorial entre os vetores definidos pelos pontos $\overrightarrow{p_1 p_2}$ e $\overrightarrow{p_2 p_3}$. Usando a convenção de leitura da imagem, isto é da esquerda para a direita e de cima para baixo, tem-se que se o produto vetorial (dado pela equação 3.3) for maior que 0(zero), p_1 , p_2 , e p_3 constituem um pico, se for menor que 0(zero) constituem um vale, e se for igual a 0(zero) formam uma reta.

$$P = (x_2 - x_1)(y_3 - y_1) - (y_2 - y_1)(x_3 - x_1). \quad (3.3)$$

Na figura 3.30, têm-se exemplos de três sequências de pontos e o seu produto vetorial. Pode-se observar que a curva azul forma um vale (produto vetorial negativo), enquanto a vermelha forma um pico (produto vetorial positivo) e a rosa forma um segmento de reta (produto vetorial igual a 0(zero)). Vale ressaltar que apenas nesta figura foi exibido o sistema de coordenadas com a origem no canto superior esquerdo. Nas demais figuras, a origem do sistema de coordenadas foi deslocado para o canto inferior esquerdo, para facilitar a visualização. A mudança para esta figura, foi feita apenas para facilitar o entendimento de como o produto vetorial foi usado para definir os picos e vales.




Figura 3.30: Exemplos de produto vetorial.

A técnica que utiliza o produto vetorial considera os vetores formados pelos pontos $(p_{i-15}, p_i, p_{i+15})$, sendo $1 \leq i \leq n$, e n o número de pontos da borda. Esta variação de 15 pixels para a esquerda e para a direita foi adotada para descartar os ispículos muito pequenos, que já foram calculados pela técnica anterior. O resultado pode ser visualizado na figura 3.31. Nesta figura é apresentada uma parte da assinatura de uma borda (imagem (a)), onde as regiões vermelhas são internas ao contorno, as marcadas em branco formam os picos e as azuis formam os vales. Na imagem (b) tem-se uma região ampliada da borda, onde pode-se verificar que as irregularidades da borda estão marcadas.




Figura 3.31: Exemplos dos picos e vales calculados usando o método desenvolvido a partir do produto vetorial.

Neste trabalho adotaram-se as duas técnicas para contagem dos ispículos e vales. Assim, esta etapa do método calcula a quantidade de ispículos e vales grandes, e também a quantidade de ispículos e vales pequenos. As duas informações são importantes para definir, respectivamente, a irregularidade e a rugosidade dos contornos das lesões.

3.6.4 Cálculo da variação de cores (C)

A variação da coloração interna das lesões foi calculada usando o canal H (matiz) do sistema de cores HSV. Este canal foi escolhido por conter a variação de cor de uma imagem. Para definir a quantidade de cores do tecido doente, a matiz foi dividida linearmente em 10 intervalos, chamados de classes de cores. Todas as cores pertencentes a um mesmo intervalo foram consideradas semelhantes. Assim, para calcular a quantidade de cores da lesão, percorre-se a região limitada pelo contorno, contando quantos pixels existem em cada um dos intervalos de cor. Após fazer esta contagem, descartam-se as classes que contêm menos de 100 pixels. Isto é feito para evitar que pixels isolados, ou regiões muito pequenas interfiram na contagem do número de cores da lesão.

Inicialmente efetuou-se a contagem das cores usando a imagem após o crescimento de regiões de Mumford-Shah. No entanto, após a realização e análise de alguns testes percebeu-se que pode ocorrer a divisão de uma área doente com cor semelhante, em duas ou mais regiões distintas, como pode-se observar na imagem (b) da figura 3.32. Nesta figura, tem-se em (a) a imagem original e em (b) o resultado da aplicação do método de Mumford-Shah. Nota-se que apesar da lesão possuir pouca variação de cor, o crescimento de regiões a representou com várias regiões distintas, como por exemplo, nas partes destacadas pelas elipses amarelas.




Figura 3.32: Exemplo do aumento na variação de cores (imagem (b)) causado pelo método de crescimento de regiões aplicado sobre a imagem (a).

Para evitar que regiões semelhantes sejam divididas em classes distintas, o cálculo da quantidade de cores foi realizado usando as imagens originais. Assim, a eliminação das classes com poucos pixels, é importante para evitar que a presença de pêlos e reflexos

interfira no número de cores calculado pelo método. Os testes e a discussão dos resultados obtidos com a aplicação do método desenvolvido neste trabalho são apresentados com mais detalhes no capítulo seguinte.

4 Resultados e discussão

Neste capítulo apresenta-se os resultados experimentais obtidos a partir da aplicação do método desenvolvido neste trabalho, em imagens de pele com lesões cancerosas. Os testes do método, bem como a comparação com resultados de um método comercial, também são abordados. Foram utilizadas 40 imagens coloridas, com resolução de 256x256 pixels, retiradas do banco de imagens Dermatlas [15] e também de imagens disponibilizadas por Goshtasby em seu sítio [23], e publicadas por Xu e colaboradores [53]. Foram utilizadas imagens contendo lesões de três classificações: lesões atípicas, lesões malignas e lesões não-malignas. As imagens destas fontes foram usadas porque, além das imagens, são disponibilizadas também informações sobre o diagnóstico final das regiões doentes.

A validação dos resultados foi feita pelo Doutor Ricardo Rossetti, especialista em doenças dermatológicas da clínica Derm de São José do Rio Preto.













4.1 Comparação de três métodos de extração de características de lesões de pele





















A tabela 4.1 apresenta algumas imagens processadas pelo método desenvolvido. Na primeira coluna da tabela, apresenta-se a numeração das imagens processadas. As lesões de todas as imagens numeradas de 1 a 3 são lesões atípicas, de 4 a 9 são não-malignas e de 10 a 20 foram diagnosticadas como lesões malignas. Na segunda coluna da tabela, são mostradas as imagens originais. Na terceira coluna são apresentadas as bordas obtidas pelo pós-processamento usando o modelo de contorno ativo GVF após o crescimento de regiões. Na quarta coluna tem-se o resultado da detecção de bordas através do método de *watershed*, usando a borda resultante do crescimento de regiões expandida e contraída como marcadores para a inundação. Na última coluna da tabela, são apresentadas as bordas resultantes do modelo de contorno ativo tradicional, aplicado sobre as fronteiras (curvas) iniciais obtidas pelo método de *watershed*.

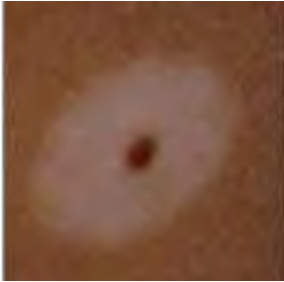



















Neste trabalho os métodos de pós-processamento foram nomeados da seguinte forma:





















- *MétodoA*: método de pós-processamento por contorno ativo GVF aplicado sobre o contorno obtido após o crescimento de regiões de Mumford-Shah,
- *MétodoB*: método *watershed* usando os marcadores definidos pela expansão e contração da borda retornada pelo crescimento de regiões, e
- *MétodoC*: aplicação do modelo de contorno ativo tradicional, usando a borda retornada pelo *watershed* como curva inicial.


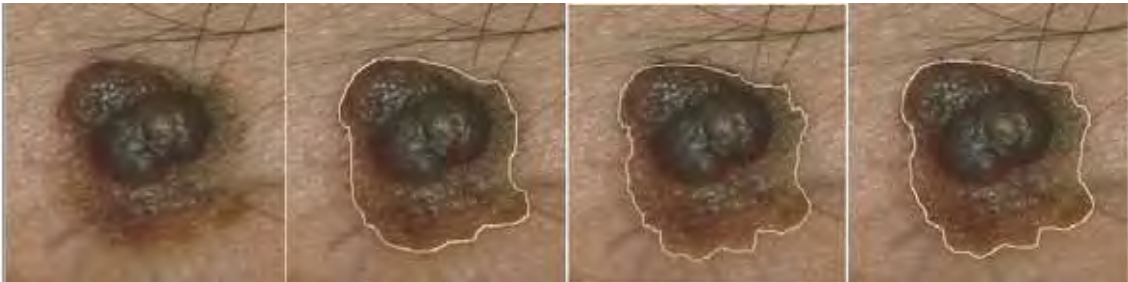
Tabela 4.1: Resultados obtidos com o método desenvolvido neste trabalho.

	Original	<i>MétodoA</i>	<i>MétodoB</i>	<i>MétodoC</i>
<u>1</u>				
<u>2</u>				
<u>3</u>				
(Cont....)				

(... Cont)				
Resultados obtidos com o método desenvolvido neste trabalho.				
	Original	MétodoA	MétodoB	MétodoC
4				
5				
6				
7				
8				
(Cont...)				

(... Cont)				
Resultados obtidos com o método desenvolvido neste trabalho.				
	Original	MétodoA	MétodoB	MétodoC
9				
10				
11				
12				
13				
(Cont...)				

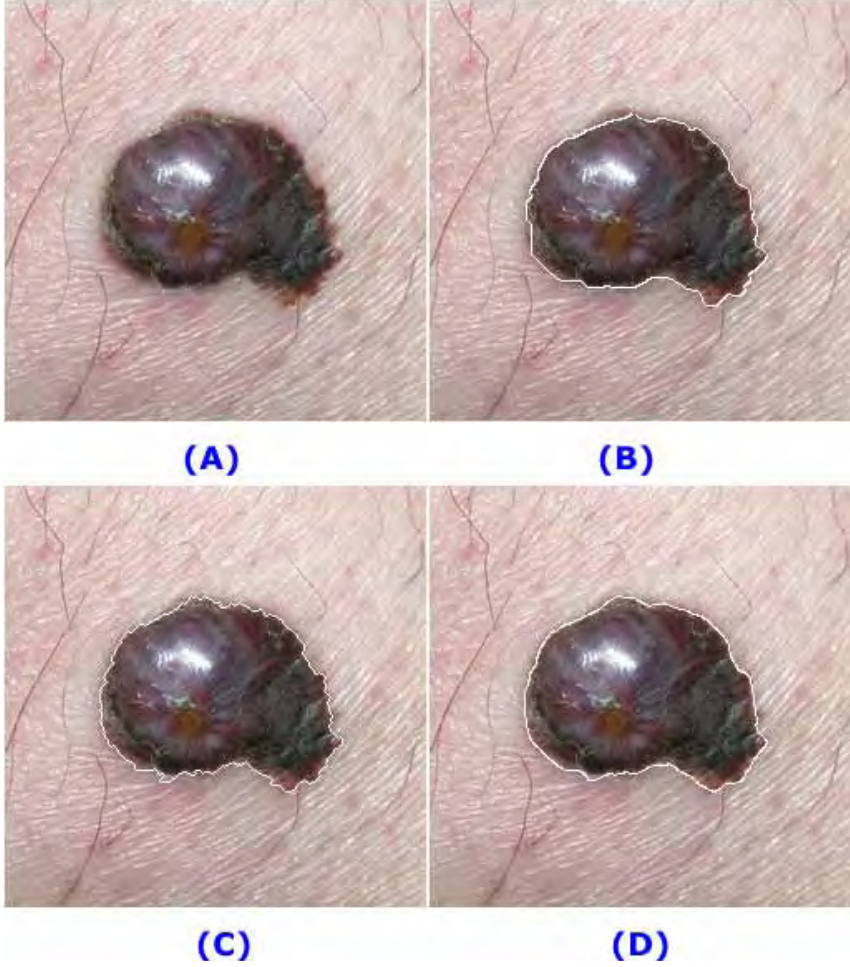
(... Cont)				
Resultados obtidos com o método desenvolvido neste trabalho.				
	Original	MétodoA	MétodoB	MétodoC
14				
15				
16				
17				
18				
(Cont....)				

(... Cont)				
Resultados obtidos com o método desenvolvido neste trabalho.				
	Original	MétodoA	MétodoB	MétodoC
19				
20				

Os resultados obtidos pelo método desenvolvido foram apresentados ao Doutor Ricardo Rossetti para validação, através de um questionário como o apresentado na tabela 4.1. Foi validado um conjunto de 23 imagens, contendo a original (imagem A), o contorno inicial da lesão detectada pela etapa de processamento (imagem B) e as bordas resultantes da aplicação do método de *watershed* (imagem C) e do modelo de contorno ativo tradicional (imagem D).

O processo de validação dividiu-se em duas etapas. Na primeira foram validadas todas as bordas, com o objetivo de definir qual método produziu o melhor resultado. Nesta etapa, todas as imagens foram analisadas pelo médico. Para cada borda detectada, foi definido qual dos três métodos adotados para o pós-processamento desenvolvido obteve melhor desempenho.

Tabela 4.2: Exemplo do questionário apresentado ao dermatologista para validação dos resultados.

 <div style="display: flex; justify-content: space-around; margin-top: 10px;"> (A) (B) </div> <div style="display: flex; justify-content: space-around; margin-top: 10px;"> (C) (D) </div>
LESÃO MALIGNA
<input type="checkbox"/> Imagem com melhor contorno.
Qualidade do melhor contorno
<input type="checkbox"/> Bom
<input type="checkbox"/> Razoável
<input type="checkbox"/> Ruim
<input type="checkbox"/> Péssimo

Analisando-se a quantidade de imagens melhor processada por cada método, obtiveram-se as taxas apresentadas na tabela 4.3.

Tabela 4.3: Taxas de acerto dos métodos de pós-processamento propostos, usando um conjunto de 40 imagens como base de teste.

Método	Melhor resultado
<i>MétodoA</i>	30,50%
<i>MétodoB</i>	8,60%
<i>MétodoC</i>	60,90%

Pelos dados das tabelas 4.1 e 4.3, nota-se que todas as lesões foram detectadas pelos três métodos abordados ($30,5\% + 8,6\% + 60,9\% = 100\%$). A aplicação do modelo de contorno ativo tradicional sobre o contorno retornado pelo *watershed* obteve o melhor resultado na maioria dos casos (aproximadamente 60.9%), ao passo que o *watershed*, sem aplicação do contorno ativo, resultou aproximadamente apenas 8,6% dos melhores resultados. Este baixo desempenho do *watershed*, aplicado às imagens de lesão de pele, justifica-se pela maior sensibilidade mostrada por este método em relação aos modelos de contorno ativo. Assim, as bordas retornadas por este apresentaram serrilhamento excessivo para a maioria dos casos testados neste trabalho.

O serrilhamento excessivo das bordas retornadas pelo *watershed*, não significa que regiões doentes deixaram de ser detectadas. Pelo contrário, o *watershed* foi capaz de envolver a maioria das lesões doentes. Este serrilhamento excessivo provocou um comprometimento na definição da irregularidade da borda, uma vez que surgiram irregularidades que não existiam, como pode-se observar nas regiões marcadas pelas elipses amarelas na imagem (a) da figura 4.1.




Figura 4.1: Erros provocados por serrilhamento excessivo resultante da aplicação do método de *watershed*.

Por outro lado, o modelo de contorno ativo tradicional tende a ajustar a curva inicial sobre o objeto, a partir da deformação desta. Assim, este fator aliado à boa detecção realizada pelo modelo *watershed* adotado, eliminou o serrilhamento excessivo da borda, retornando os melhores resultados na maioria dos casos, como por exemplo, na imagem (b) da figura 4.1.

Após detectar as lesões e extrair suas bordas, aplicou-se a etapa de caracterização das lesões. Nesta etapa, o objetivo é extrair características que possam ser usadas para diagnosticar as áreas doentes de acordo com a regra ABCD (assimetria, irregularidade da borda, variação da coloração interna e diâmetro das lesões). Na tabela 4.3, têm-se os dados retornados por esta etapa.

Tabela 4.4: Características extraídas das lesões.

Img	Assimetria	Irregularidade da borda	Cores	Diâmetro (pixels)
1	levemente as-simétrica	7 ispículos e 5 vales grandes, e 13 ispículos pequenos	9	167
2	levemente as-simétrica	7 ispículos e 4 vales grandes, e 17 ispículos pequenos	4	196
3	levemente as-simétrica	3 ispículos e 0 vales grandes, e 7 ispículos pequenos	3	198
4	levemente as-simétrica	8 ispículos e 1 vales grandes, e 18 ispículos pequenos	1	150
5	levemente as-simétrica	11 ispículos e 4 vales grandes, e 25 ispículos pequenos	4	216
6	levemente as-simétrica	9 ispículos e 9 vales grandes, e 25 ispículos pequenos	2	229
7	simétrica	8 ispículos e 7 vales grandes, e 21 ispículos pequenos	2	207
8	levemente as-simétrica	7 ispículos e 2 vales grandes, e 18 ispículos pequenos	1	211
9	acentuadamente assimétrica	9 ispículos e 2 vales grandes, e 19 ispículos pequenos	1	192
(Cont...)				

(... Cont)				
Características extraídas das lesões.				
10	levemente as-simétrica	9 ispículos e 7 vales grandes, e 18 ispículos pequenos	2	228
11	acentuadamente assimétrica	6 ispículos e 3 vales grandes, e 18 ispículos pequenos	10	162
12	acentuadamente assimétrica	4 ispículos e 3 vales grandes, e 10 ispículos pequenos	10	119
13	acentuadamente assimétrica	6 ispículos e 3 vales grandes, e 21 ispículos pequenos	8	149
14	acentuadamente assimétrica	4 ispículos e 0 vales grandes, e 8 ispículos pequenos	2	62
15	acentuadamente assimétrica	4 ispículos e 0 vales grandes, e 3 ispículos pequenos	6	163
16	acentuadamente assimétrica	8 ispículos e 3 vales grandes, e 18 ispículos pequenos	10	159
17	acentuadamente assimétrica	2 ispículos e 1 vales grandes, e 18 ispículos pequenos	10	237
18	acentuadamente assimétrica	7 ispículos e 2 vales grandes, e 14 ispículos pequenos	3	132
19	acentuadamente assimétrica	6 ispículos e 2 vales grandes, e 10 ispículos pequenos	2	105
20	simétrica	7 ispículos e 5 vales grandes, e 16 ispículos pequenos	2	205

A assimetria foi definida analisando-se a diferença dos lados da lesão em relação à maior diagonal que a divide em duas partes. Para esta característica, propuseram-se três possíveis classificações: simétrica, levemente assimétrica e acentuadamente assimétrica. Nota-se que a maioria das lesões não-malignas (de 4 a 9) foram classificadas como simétricas ou levemente assimétricas. Enquanto isso, com exceção das lesões 10 e 20, as malignas foram classificadas como acentuadamente assimétricas, atendendo à componente *A* da regra ABCD. Fazendo uma análise visual das lesões 9 e 20, percebe-se que apesar delas terem sido consideradas acentuadamente assimétrica e simétrica, e serem não-maligna e maligna, respectivamente, a classificação delas ficou dentro do esperado, como pode-se observar na figura 4.2. Nesta figura tem-se a imagem 9 em (a) e 20 em (b),

com a diagonal maior desenhada em vermelho.




Figura 4.2: Imagens 9 em (a) e 20 em (b), com suas respectivas diagonais maiores.

A quantidade de ispículos e vales pode auxiliar o dermatologista na definição da irregularidade das bordas das lesões. Pode-se observar na tabela 4.3, que a quantidade de ispículos grandes e pequenos aparece na terceira coluna. Estes dados foram retornados para que o dermatologista tenha a idéia da irregularidade das bordas. Vale ressaltar que, para fazer a análise da irregularidade, deve-se considerar o tamanho da lesão, uma vez que a tendência é que o número de ispículos seja menor quando a região doente for menor.

Nota-se também que nas lesões atípicas e malignas (imagens 1 a 3 e 10 a 20, respectivamente), a quantidade de cores internas foi maior do que nas lesões não-malignas (imagens de 4 a 9). Ao passo que foram encontradas de 1 a 2 cores na maioria das lesões não malignas, na maior parte das malignas detectou-se mais de 5 cores, o que também atende à regra ABCD.

A medida do diâmetro foi calculada em pixels, pois a maioria das imagens usadas nos testes não traziam informações que permitissem montar uma relação, e definir aproximadamente esta medida em milímetros. Na figura 4.3 tem-se a única imagem dos bancos de imagens adotados com uma referência para cálculo da distância em milímetros. Em (a) tem-se uma imagem contendo uma lesão de pele com aproximadamente 5 milímetros de diâmetro, como pode-se observar pela régua usada como referência na parte superior da imagem (a). Na imagem (b) tem-se o valor em milímetros, do diâmetro calculado pelo método de caracterização desenvolvido. Este cálculo foi feito a partir da relação entre o número de pixels da maior diagonal da lesão, e o número de pixels necessários para representar cada milímetro na imagem original. Nota-se que a borda da lesão e o seu diâmetro foram processados satisfatoriamente pelo método desenvolvido.




Figura 4.3: Cálculo do diâmetro da lesão. Em (a) o diâmetro da lesão definido pelo especialista médico, e em (b) o diâmetro calculado a partir da borda retornada pelo método proposto neste trabalho.

Após obter estes resultados, iniciou-se a segunda etapa de validação dos mesmos. Nesta etapa do processo de validação, foram avaliadas a qualidade das melhores bordas detectadas e extraídas. Os dados desta análise são apresentados na tabela 4.5.

Tabela 4.5: Avaliação da qualidade das melhores bordas, considerando um conjunto de 40 imagens como base de teste.

Resultados aceitáveis	Resultados ruins
91,30%	8,70%

Nota-se, a partir dos dados apresentados nas tabelas 4.3 e 4.5, que o procedimento desenvolvido é promissor, e obteve um bom desempenho. Em todos os casos testados, o método foi capaz de detectar as lesões, sendo que em aproximadamente 91,3% destes casos, as bordas extraídas envolveram satisfatoriamente as regiões doentes. Nos demais casos, os contornos extraídos não foram bons, mas vale ressaltar que as lesões foram detectadas. Na figura 4.4 tem-se um exemplo de imagem, cuja lesão foi detectada, mas sua borda foi classificada como ruim. Pode-se observar que a borda não envolveu completamente a lesão, deixando regiões doentes fora do contorno (regiões marcadas em amarelo).



Figura 4.4: Imagem com borda da lesão detectada classificada como ruim.

Como pode-se observar nas imagens da tabela 4.1, os testes foram feitos sobre um conjunto contendo imagens com várias características. Foram usadas imagens com bom contraste (imagem 12), com baixo contraste (imagens 1 e 2), com pouco ruído (imagem 14) e também em imagens com a presença de pêlos e reflexos (imagens 11, 13, 16, 17 e 19). Em todos os tipos de imagens, os resultados da extração e caracterização das bordas foram satisfatórios e muito animadores, principalmente em relação às imagens com a presença de pêlos. Nestas, o método foi capaz de detectar e extrair as bordas satisfatoriamente, eliminando a interferência causada por pêlos.

O método desenvolvido mostrou-se capaz de detectar, extrair e caracterizar as bordas de lesões de pele, em imagens variadas. Mesmo que estas sofram interferências causadas pela presença de pêlos ou reflexos. Para uma melhor análise dos resultados, apresenta-se na próxima seção, a comparação dos resultados obtidos por este método e por um *software* disponível para uso da comunidade médica.

4.2 Comparação do método desenvolvido em relação ao método utilizado comercialmente

Nesta seção apresenta-se uma comparação, feita entre as bordas obtidas pelo processamento com o algoritmo desenvolvido neste trabalho e usando um *software* disponibilizado para uso da comunidade médica. Este *software*, chamado *SkinSeg*, foi criado por A. Goshtasby, Marcel Jackowski, Lang Xu e Thisath kularatna, em projeto desenvolvido no *Intelligent Systems Laboratory* da *Wright State Univeristy* [53]. Este *software* é usado para extrair automaticamente as bordas de lesões de câncer de pele, é de uso gratuito e pode ser obtido na seção de aplicações médicas do *efg's (Earl F. Glynn) Computer Lab* [21].

Na figura 4.5 tem-se na linha 1, os resultados obtidos usando o *software SkinSeg* e na linha 2 as bordas extraídas pela abordagem desenvolvida neste trabalho. Nestes casos, as imagens apresentam bom contraste, pouca presença de ruídos e interferência da iluminação externa, sendo os resultados semelhantes.




Figura 4.5: Comparação entre os resultados obtidos pelo *software SkinSeg* (linha 1) e o método desenvolvido neste trabalho (linha 2).

Fazendo uma comparação visual entre os resultados obtidos pelo método desenvolvido e pelo *SkinSeg*, percebeu-se que este último não foi capaz de detectar algumas lesões. Quando foram processadas imagens com a presença de pêlos e/ou que sofrem interferência de iluminação, como por exemplo os reflexos, o algoritmo desenvolvido mostrou-se mais eficiente, como visto na tabela 4.6. Usando imagens variadas, com diferentes interferências de ruído, o método *SkinSeg* obteve aproximadamente 64% de resultados aceitáveis, ao passo que o método proposto produziu cerca de 91% de bons resultados.

Tabela 4.6: Comparação da qualidade das bordas resultantes do método desenvolvido e do *SkinSeg*.

Método	Resultados aceitáveis	Resultados ruins
Método Desenvolvido	91,30%	8,70%
<i>SkinSeg</i>	64%	36%

Pode-se observar a diferença dos resultados na figura 4.6. Nesta figura, as linhas 1 e 3 apresentam os resultados retornados usando o *software SkinSeg*, enquanto as linhas 2 e 4 contêm o resultado do método desenvolvido neste trabalho. Pode-se notar que em

alguns casos, a diferença entre os contornos obtidos pelos dois métodos é muito acentuada, como nas imagens (c), (e) e (f). Nestes casos, as bordas obtidas pelo *SkinSeg* não foram suficientes para identificar as lesões. Em outros casos, as bordas retornadas pelo *SkinSeg* envolveram as regiões doentes. Entretanto, detectaram algumas regiões saudáveis como sendo doentes, como foi o caso das imagens (a), (b) e (d), onde cada região é mostrada em uma cor diferente.




Figura 4.6: Comparação entre os resultados obtidos pelo *software SkinSeg* (linhas 1 e 3) e o método desenvolvido neste trabalho (linhas 2 e 4).

O procedimento elaborado neste trabalho obteve resultados melhores dos que o *Skin-Seg*. Este último, quando aplicado em imagens “danificadas” pela presença de pêlos e reflexos, não foi capaz de detectar as lesões, retornando ainda, regiões saudáveis como sendo pertencentes às áreas doentes, como observa-se nas linhas 1 e 3 da figura 4.6.

Conclusão

Apresentou-se neste trabalho, o desenvolvimento de um método de detecção, extração e caracterização de lesões de pele em imagens coloridas, com o objetivo de auxiliar o dermatologista a visualizar mais claramente as características das áreas doentes na imagem dermatológica. Ao aplicar a suavização seletiva, o método desenvolvido eliminou parte dos ruídos da imagem, reduzindo a interferência causada pela presença de pêlos e reflexos devido à iluminação. Aplicando o crescimento de regiões na imagem suavizada, obteve-se um contorno inicial, usado para o pós-processamento pelos métodos de *watershed* e contorno ativo.

A aplicação do *watershed* foi importante para melhorar a detecção da borda, ao passo que o modelo de contorno ativo tradicional aplicado na sequência, ajustou o contorno sobre a lesão, eliminando o serrilhamento excessivo gerado na borda pelas etapas anteriores do método. Além disso, o pós-processamento realizado com estes dois métodos permitiu que a borda fosse refinada, eliminando as interferências de pêlos muito próximos ao limite das regiões doentes, e que ainda não tivessem sido eliminadas pela suavização.

Ao extrair as bordas das lesões, e sobrepô-las às imagens originais com uma cor de destaque, aumenta-se a precisão da análise médica sobre as características definidas pela regra ABCD, pois os limites das lesões ficam mais evidentes. A classificação realizada neste trabalho fornece elementos que também podem ser usados para fazer a análise da imagem, como a quantidade de irregularidades presentes nas bordas, a variação de cor das regiões doentes, bem como o seu diâmetro e assimetria.

A utilização da suavização por difusão anisotrópica foi fundamental para eliminação da maior parte da interferência causada por pêlos. Por se tratar de uma suavização seletiva, onde o efeito de degradação da borda é retardado, e por usar uma aproximação automática do número de iterações para a difusão anisotrópica, alguns resquícios dos pêlos que localizam-se sobre as bordas podem não ser eliminados no pré-processamento. Estes “pedaços” de pêlos podem gerar curvas inexistentes nos contornos após a aplicação do crescimento de regiões de Mumford-Shah. O pós-processamento com o modelo de contorno ativo permitiu que estas falsas curvas fossem eliminadas, separando a área da lesão do

restante da imagem.

Com base nos resultados obtidos, pode-se afirmar que para as imagens processadas, a aplicação do algoritmo de *watershed*, usando a borda resultante do crescimento de regiões expandida e contraída, como marcadores para a inundação, apresentou melhor detecção das lesões. Este melhor desempenho do *watershed* para detectar as lesões, é decorrente do fato de usar a curva produzida pelas etapas de pré-processamento e segmentação com o crescimento de regiões de Mumford-Shah. Apesar de não envolver completamente todas as lesões, esta curva possui o formato (topologia) semelhante à ideal para envolver todas as áreas doentes. Por isso, quanto melhor for o resultado destas duas etapas iniciais do método, melhor é o resultado final.

Trabalhos futuros

Como propostas de trabalhos futuros, podem ser sugeridos: a melhoria do método *merge* para binarização da imagem após o crescimento de regiões de Mumford-Shah, e o desenvolvimento de algoritmos que permitam a melhoria do desempenho do método, tais como a utilização de técnicas de computação de alto desempenho e o desenvolvimento do método usando programação paralela ou computação distribuída. Estas técnicas permitem a execução mais rápida do método, possibilitando o processamento de imagens com dimensões maiores em tempo aceitável, produzindo bordas com mais detalhes. O modelo de contorno ativo tradicional adotado, tem dificuldades para manipular mudanças de topologia da curva inicial. Portanto, outra proposta de trabalho futuro, é testar outros modelos de contornos ativos para o pós-processamento, como por exemplo, o *level set* [26], que supera as dificuldades topológicas, permitindo mudanças topológicas na curva à medida que esta vai sendo deformada.

Referências

- [1] A. C. M. Alvin. *Métodos numéricos em engenharia nuclear*. Centauro, 2007 edition, 2007.
- [2] L. Ballerini. Genetic snakes for medical images segmentation. Em *EvoIASP '99/EuroEcTel '99: Proceedings of the First European Workshops on Evolutionary Image Analysis, Signal Processing and Telecommunications*, páginas 59–73, London, UK, 1999. Springer-Verlag.
- [3] C. A. Z. Barcelos, M. Boaventura, and E. C. Silva. A well-balanced flow equation for noise removal and edge detection. Em *IEEE Transactions on Image Processing*, volume 12, páginas 751–763, 2003.
- [4] C. A. Z. Barcelos and V. B. Pires. An automatic based nonlinear diffusion equations scheme for skin lesion segmentation. *Applied Mathematics and Computation*, 215(1):251–261, 2009.
- [5] S. Beucher and C. Lantuejoul. Use of watersheds in contour detection. Em *International Workshop on Image Processing: Real-time Edge and Motion Detection/Estimation, Rennes, France.*, Setembro 1979.
- [6] S. Beucher and C. D. M. Mathmatique. The watershed transformation applied to image segmentation. Em *Scanning Microscopy International*, páginas 299–314, 1991.
- [7] A. C. Camargo. Equipe médica do hospital. câncer de pele: Não melanoma. disponível em: <http://www.hcanc.org.br/index.php?page=14idtipocancer=28>. acesso em dezembro, 2009.
- [8] A. C. Camargo. Equipe médica do hospital. câncer de pele: Melanoma. disponível em: <http://www.hcanc.org.br/index.php?page=14idtipocancer=7>. acesso em dezembro, 2009.
- [9] J. Canny. A computational approach to edge detection. *IEEE Trans. Pattern Anal. Mach. Intell.*, 8(6):679–698, 1986.
- [10] M. E. Celebi, Y. A. Aslandogan, and P. R. Bergstresser. Unsupervised border detection of skin lesion images. Em *ITCC '05: Proceedings of the International Conference on Information Technology: Coding and Computing (ITCC'05) - Volume II*, páginas 123–128, Washington, DC, USA, 2005. IEEE Computer Society.
- [11] E. Claridge, J. D. M. Smith, and P. N. Hall. Evaluation of border irregularity in pigmented skin lesions against a consensus of expert clinicians. Em *Medical Image Understanding and Analysis*, páginas 85–88, 1998.

- [12] L. D. Cohen. On active contour models and balloons. *CVGIP: Image Underst.*, 53(2):211–218, 1991.
- [13] L. Coser. Filtro de difusão anisotrópico orientado por evidência de borda. Tese de Mestrado, Departamento de Ciência da Computação - Universidade Federal de Santa Catarina, Florianópolis, SC - Brasil, 2009.
- [14] A. M. de Souza. Identificação de tumores cerebrais por meio do modelo de contornos ativos e algoritmos genéticos. Tese de Mestrado, Departamento de Informática - Universidade Federal do Paraná, Curitiba, PR - Brasil, 2003.
- [15] DermAtlas. Dermatology image atlas. disponível em: <http://dermatlas.med.jhmi.edu/derm>. acesso em dezembro, 2009.
- [16] H. Digabel and C. Lantuéjoul. Iterative algorithms. Em *Quantitative analysis of microstructures in materials sciences, biology and medicine*, páginas 85–99, 1978.
- [17] E. Dougherty and R. Lotufo. Hands-on morphological image processing. Em *SPIE PRESS*, 2003.
- [18] A. Drozdek. *Data Structures and Algorithms in C++*. Brooks/Cole Publishing Co., Pacific Grove, CA, USA, 2000.
- [19] A. Dumitras and A. N. Venetsanopoulos. A comparative study of snake models with application to object shape description in bi-level and gray-level images. Em *IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing*, 2001.
- [20] A. Falcão, R. A. Lotufo, and G. Araujo. The image foresting transformation. Relatório técnico, IEEE Trans. on Pattern Analysis and Machine Intelligence, 2000.
- [21] E. F. Glynn. Medical applications. disponível em: <http://www.efg2.com/lab/library/imageprocessing/medicalapplications.htm>. acesso em dezembro, 2009.
- [22] R. C. Gonzalez, R. E. Woods, and S. L. Eddins. *Digital Image Processing Using MATLAB*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2003.
- [23] A. Goshtasby. Segmentation of skin cancer images. disponível em: http://www.cs.wright.edu/~agoshtas/paper_fig.html. acesso em dezembro, 2009.
- [24] Guide. Skin cancer images. disponível em: <http://www.skincancerguide.ca/prevention/images.html>. acesso em dezembro, 2009.
- [25] Guide. Skin cancer self-examination. disponível em: http://www.skincancerguide.ca/prevention/self_examination.html. acesso em dezembro, 2009.
- [26] W. Jiming and Z. Xuefeng. A multi-phase level set method for image segmentation based on the mumford-shah model. Em *GCIS '09: Proceedings of the 2009 WRI Global Congress on Intelligent Systems*, páginas 344–349, Washington, DC, USA, 2009. IEEE Computer Society.

- [27] M. Kass, A. Witkin, and D. Terzopoulos. Snakes: Active contour models. *International Journal of Computer Vision*, 1(4):321–331, Janeiro 1988.
- [28] J. Liang, T. McInerney, and D. Terzopoulos. United snakes. Em *ICCV '99: Proceedings of the International Conference on Computer Vision-Volume 2*, página 933, Washington, DC, USA, 1999. IEEE Computer Society.
- [29] B. Madeira and L. Velho. Utilização de um modelo de contorno ativo para extração de arestas em imagens. *Anais do ERMAC 2001 - Encontro Regional de Matemática Aplicada e Computacional*, 2001.
- [30] T. McInerney and D. Terzopoulos. Topology adaptive deformable surfaces for medical image volume segmentation. 18(10):840–850, Outubro 1999.
- [31] F. Meyer. Color image segmentation. Em *Proceedings of the International Conference on Image Processing and its Applications*, páginas 303–306, 1992.
- [32] F. Meyer. Topographic distance and watershed lines. *Signal Process.*, 38(1):113–125, 1994.
- [33] F. Meyer and S. Beucher. Morphological segmentation. 1(1):21–46, Setembro 1990.
- [34] J. D. Morris-Smith. *Characterisation of the appearance of pigmented skin lesions*. Tese de PhD, The University of Birmingham, 1996.
- [35] D. Mumford and J. Shah. Optimal approximations by piecewise smooth functions and associated variational problems. *Communications on Pure and Applied Mathematics*, 42(5):577–685, 1989.
- [36] N. Nordström. Biased anisotropic diffusion—a unified regularization and diffusion approach to edge detection. Em *ECCV 90: Proceedings of the first european conference on Computer vision*, páginas 18–27, New York, NY, USA, 1990. Springer-Verlag New York, Inc.
- [37] OpenCV. Open computer vision library. disponível em: <http://sourceforge.net/projects/opencvlibrary>. acesso em dezembro, 2009.
- [38] G. Peccini. Segmentação de imagens por watersheds: uma implementação utilizando a linguagem java. Relatório técnico, Curso de Ciência da Computação. Universidade Federal de Santa Maria., Santa Maria, 2004.
- [39] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. Relatório técnico, Berkeley, CA, USA, 1988.
- [40] V. B. Pires and C. A. Z. Barcelos. Edge detection of skin lesions using anisotropic diffusion. Em *ISDA '07: Proceedings of the Seventh International Conference on Intelligent Systems Design and Applications*, páginas 363–370, Washington, DC, USA, 2007. IEEE Computer Society.
- [41] M. I. Rajab, M. S. Woolfson, and S. Morgan. Application of region-based segmentation and neural network edge detection to skin lesions. Em *Computerized Medical Imaging and Graphics*, páginas 61–68, 2004.

- [42] J.-F. Rivest, P. Soille, and S. Beucher. Morphological gradients. *Journal of Electronic Imaging*, 2(4):326–336, 1993.
- [43] J. B. T. M. Roerdink and A. Meijster. The watershed transform: Definitions, algorithms and parallelization strategies, 2001.
- [44] J. M. Rondina. Segmentação interativa do ventrículo esquerdo em sequências de imagens de ressonância magnética (Cine MR). Tese de Mestrado, Departamento de Engenharia Elétrica e de Computação - Universidade Estadual de Campinas, Campinas, SP - Brasil, 2001.
- [45] V. T. Santos. Segmentação de Imagens Mamográficas para Detecção de Nódulos em Mamas Densas. Tese de Mestrado, Departamento de Engenharia Elétrica - Universidade de São Paulo, São Carlos, SP - Brasil, 2002.
- [46] J. L. Semmlow. *Biosignal and biomedical image processing : MATLAB-based applications*. Marcel Dekker, New York, 2004.
- [47] A. Singh, D. Terzopoulos, and D. B. Goldgof. *Deformable Models in Medical Image Analysis*. IEEE Computer Society Press, Los Alamitos, CA, USA, 1998.
- [48] P. Soille. *Morphological Image Analysis: Principles and Applications*. Springer-Verlag, 1999.
- [49] W. Stoecker, Z. Zhang, R. Moss, S. Umbaugh, and F. Ercal. *Boundary Detection Techniques in Medical Image Processing*. Taylor Francis, illustrated edition, 1997.
- [50] L. Vincent and P. Soille. Watersheds in digital spaces: An efficient algorithm based on immersion simulations. *IEEE Trans. Pattern Anal. Mach. Intell.*, 13(6):583–598, 1991.
- [51] C. Xu and J. L. Prince. Gradient vector flow: A new external force for snakes. Em *IEEE Proc. Conf. On*, páginas 66–71, 1997.
- [52] C. Xu and J. L. Prince. Snakes, shapes, and gradient vector flow. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, 7(3):359–369, 1998.
- [53] L. Xu, M. Jackowski, A. A. Goshtasby, D. Roseman, S. Bines, C. T. Yu, A. Dhawan, and A. C. Huntley. Segmentation of skin cancer images. *Image Vision Comput.*, 17(1):65–74, 1999.

Apêndice

Produção científica

As produções científicas relativas ao trabalho são apresentadas a seguir:

- A. F. de Araujo, A. S. Pereira, N. Marranghello, T. A. Dócusse, J. M. R. S. Tavares. **An analysis on segmentation methods for skin lesions.** *ECCOMAS VIPI-MAGE: II ECCOMAS Thematic Conference on Computational Vision and Medical Image Processing*. Porto Portugal 2009.
- A. F. de Araujo, A. S. Pereira, N. Marranghello, J. M. R. S. Tavares. **Segmentação automática de lesões de pele usando difusão anisotrópica e crescimento de regiões.** *CNMAC: Congresso Nacional de Matemática Aplicada e Computacional*. UFMT - Cuiabá Brasil 2009.
- A. F. de Araujo, A. S. Pereira, N. Marranghello, J. Rogéri, A. J. do Nascimento, J. M. R. S. Tavares. **Estimativa automática para o número de iterações da difusão anisotrópica para pré-processamento de imagens digitais.** *CILAMCE: Congresso Ibero-Latino-Americano de Métodos Computacionais em Engenharia*. Armação dos Búzios Brasil 2009
- A. F. de Araujo, A. S. Pereira, N. Marranghello, J. Rogéri, J. M. R. S. Tavares. **Nonlinear smoothing of skin lesions images driven by derivative filters.** **Submetido ao CMBBE: 9th International Symposium Computer Methods in Biomechanics and Biomedical Engineering.** Valência Espanha 2010
- A. F. de Araujo, A. S. Pereira, N. Marranghello, J. M. R. S. Tavares. **Segmentation of skin lesions using active contours initialized by region growing.** *Submetido ao IVECCM: European Congress on Computational Mechanics*. Paris França 2010